



**HAL**  
open science

# Modèles statistiques avancés pour la segmentation non supervisée des images dégradées de l'iris

Meriem Yahiaoui

► **To cite this version:**

Meriem Yahiaoui. Modèles statistiques avancés pour la segmentation non supervisée des images dégradées de l'iris. Traitement du signal et de l'image [eess.SP]. Université Paris Saclay (COMUE), 2017. Français. NNT : 2017SACLL006 . tel-01591556

**HAL Id: tel-01591556**

**<https://theses.hal.science/tel-01591556>**

Submitted on 21 Sep 2017

**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.

NNT : 2017SACLL006

**THÈSE DE DOCTORAT  
DE L'UNIVERSITÉ PARIS-SACLAY  
PRÉPARÉE À TÉLÉCOM SUDPARIS**

**ÉCOLE DOCTORALE N°580**

**Sciences et technologies de l'information et de la communication**

*Spécialité de doctorat : Traitement du signal et des images*

**Présentée par  
Meriem YAHIAOUI**

**Modèles statistiques avancés pour la segmentation non  
supervisée des images dégradées de l'iris**

**Date de soutenance : 11/07/2017**

**Jury de soutenance :**

<i>M<sup>r</sup></i> Liming Chen	(Professeur, École Centrale de Lyon) Président de jury
<i>M<sup>r</sup></i> Stéphane Derrode	(Professeur, École Centrale de Lyon) Rapporteur
<i>M<sup>r</sup></i> Christophe Collet	(Professeur, Télécom Physique Strasbourg ) Rapporteur
<i>M<sup>me</sup></i> Florence Tupin	(Professeur, Télécom ParisTech, France) Examinatrice
<i>M<sup>me</sup></i> Bernadette Dorizzi	(Professeur, Télécom SudParis, France) Directrice de thèse
<i>M<sup>r</sup></i> Emmanuel Monfrini	(MC, Télécom SudParis, France) Encadrant de thèse

# Remerciements

En tout premier lieu, je tiens à remercier chaleureusement ma directrice de thèse, *M<sup>me</sup>* Bernadette Dorizzi, pour sa rigueur scientifique, pour ses précieux conseils et son soutien tout au long de ce travail. J'adresse un grand merci à mon encadrant *M<sup>me</sup>* Emmanuel Monfrini. J'ai apprécié nos échanges durant toute la thèse et en particulier son aide pour la maîtrise des modèles markoviens et leur utilisation dans le domaine de la segmentation d'images de l'iris. Je leur suis reconnaissante.

Je remercie tous les membres du jury d'avoir accepté d'évaluer mon travail et pour l'intérêt qu'ils lui ont porté :

- *M<sup>me</sup>* Liming Chen d'avoir présidé le Jury ;
- *M<sup>r</sup>* Stéphane Derrode et *M<sup>r</sup>* Christophe Collet d'avoir rapporté mon travail de thèse et pour leurs remarques constructives qui ouvrent de nouvelles perspectives ;
- *M<sup>me</sup>* Florence Tupin d'avoir examiné mon travail.

Je remercie *M<sup>r</sup>* Badr-Eddine Benkelfat et *M<sup>r</sup>* Wojciech Pieczynski de m'avoir accueilli dans leur département (CITI et EPH) et particulièrement à Nano Innov.

Je tiens à remercier mes parents, je suis profondément reconnaissante pour ce qu'ils ont fait pour moi. Une chose est sûre : je ne l'oublierai jamais. J'espère que j'étais à la hauteur de leur attente. Ma sœur Itheri, j'ai apprécié le soutien constant et les encouragements que tu m'as apportés. Ton aide dans des moments si particuliers de ma vie est un véritable cadeau, tu es mon ange gardien. Mon mari Karim, sache que ton aide et ta main tendue resteront à jamais dans mon cœur. Merci de m'avoir supportée surtout pendant les moments difficiles, merci pour ta présence à mes côtés, pour l'attention que tu me portes, pour ta gentillesse. . .

---

Mes frères Aboubakeur et Nadjib, toujours présents malgré la distance, merci de m'avoir toujours écoutée et accompagnée, et de m'avoir permis de changer les idées.

Mon cher YouYou, tu es le véritable cadeau, le jour de ta naissance reste pour moi un souvenir merveilleux. Merci pour les centaines de sourires qui ont façonné ma vie ainsi les moments de pur bonheur que je n'oublierai jamais. Un remerciement particulier à Amor pour l'aide apportée surtout pour la compréhension de certains problèmes statistiques.

Un gros bisou à mon neveu Sikou et ma nièce Aryam, j'espère que je peux profiter de votre présence prochainement. Merci à tata Hafidha, Majeda, Amina, Ibtissem, pour l'accueil chaleureux à chacune de mes visites.

Un grand merci pour des personnes, tout simplement, géniales : Nadia Othman, François Lamare, Sana Chafik et Nicolas Granger, Hajer Khlaifi, Christian Muingi. Je n'oublierai jamais les moments de bonheur et de partage que nous avons passé ensemble tout au long de ces années, je vous aime.

J'adresse mes sincères remerciements à  $M^r$  Laidoudi Bouakkar pour la lecture attentive et la correction de mon rapport de thèse et à  $M^r$  Mounim El Yacoubi pour ses encouragements et son soutien durant cette thèse.

Je remercie encore toute personne qui a pu assister à ma soutenance. Mille merci à toute ma famille, mes amis, mes voisins.

# Résumé

---

L'IRIS est considérée comme une des modalités les plus robustes et les plus performantes en biométrie à cause de ses faibles taux d'erreurs. Ces performances ont été observées dans des situations contrôlées, qui imposent des contraintes lors de l'acquisition pour l'obtention d'images de bonne qualité. Relâcher ces contraintes, au moins partiellement, implique des dégradations de la qualité des images acquises et par conséquent une réduction des performances de ces systèmes. Une des principales solutions proposées dans la littérature pour remédier à ces limites est d'améliorer l'étape de segmentation de l'iris. L'objectif principal de ce travail de thèse a été de proposer des méthodes originales pour la segmentation des images dégradées de l'iris. Les chaînes de Markov ont été déjà proposées dans la littérature pour résoudre des problèmes de segmentation d'images. Dans ce cadre, une étude de faisabilité d'une segmentation non supervisée des images dégradées d'iris en régions par les chaînes de Markov a été réalisée, en vue d'une future application en temps réel. Différentes transformations de l'image et différentes méthodes de segmentation grossière pour l'initialisation des paramètres ont été étudiées et comparées. Les modélisations optimales ont été introduites dans un système de reconnaissance de l'iris (avec des images en niveaux de gris) afin de produire une comparaison avec les méthodes existantes. Finalement une extension de la modélisation basée sur les chaînes de Markov cachées, pour une segmentation non supervisée des images d'iris acquises en visible, a été mise en place.

**Mots-clés :** Segmentation non supervisée, segmentation de l'iris, chaînes de Markov cachées, couples et triplets, apprentissage, perceptron multi-couche, linéarisation de l'image.

---

# Abstract

---

IRIS is considered as one of the most robust and efficient modalities in biometrics because of its low error rates. These performances were observed in controlled situations, which impose constraints during the acquisition in order to obtain good quality images. The renouncement of these constraints, at least partially, implies degradations in the quality of the acquired images and therefore a degradation of these systems' performances. One of the main proposed solutions in the literature to take into account these limits is to propose a robust approach for iris segmentation. The main objective of this thesis is to propose original methods for the segmentation of degraded images of the iris. Markov chains have been well solicited to solve image segmentation problems. In this context, a feasibility study of unsupervised segmentation into regions of degraded iris images by Markov chains was performed. Different image transformations and different segmentation methods for parameters initialization have been studied and compared. Optimal modeling has been inserted in iris recognition system (with grayscale images) to produce a comparison with the existing methods. Finally, an extension of the modeling based on the hidden Markov chains has been developed in order to realize an unsupervised segmentation of the iris images acquired in visible light.

**Keywords :** Unsupervised segmentation, iris segmentation, Hidden Markov Chains, Pairwise Markov Chains, Triplet Markov Chains ,learning, multilayer perceptron, image linearization.

---

# Table des matières

<b>Liste des acronymes</b>	<b>ix</b>
<b>Introduction</b>	<b>2</b>
<b>1 Généralités biométriques</b>	<b>8</b>
1.1 Systèmes biométriques . . . . .	12
1.2 Évaluation des performances des systèmes biométriques . . . . .	14
1.2.1 Les mesures des taux d'erreurs . . . . .	15
1.2.2 Les courbes de performances . . . . .	16
1.2.3 Les points de fonctionnement . . . . .	17
1.3 Système de reconnaissance de l'iris . . . . .	18
1.3.1 Module d'acquisition d'images d'iris . . . . .	20
1.3.1.1 Acquisition d'images dans des conditions contrôlées . . . . .	20
1.3.1.2 Acquisition d'image dans des conditions non contrôlées . . . . .	22
1.3.2 Module de reconnaissance de l'iris . . . . .	26
1.3.2.1 Segmentation de l'iris . . . . .	26
1.3.2.2 Normalisation de l'iris . . . . .	26
1.3.2.3 Extraction des caractéristiques . . . . .	27
1.3.2.4 Comparaison des motifs . . . . .	28
1.4 Base de données de l'iris . . . . .	30
1.4.1 ICE2005 . . . . .	30
1.4.2 CASIA-IrisV4-distance . . . . .	31

1.4.3	UBIRIS . . . . .	32
<b>2</b>	<b>État de l’art des méthodes de segmentation de l’iris</b>	<b>35</b>
2.1	Approches basées sur la forme des contours de l’œil . . . . .	37
2.1.1	Approches basées sur l’opérateur intégrodifférentiel . . . . .	37
2.1.2	Approches basées sur la transformée de Hough . . . . .	39
2.1.3	Autres approches . . . . .	41
2.1.4	Limitations des approches basées sur la forme des contours de l’œil . . . . .	46
2.2	Approches basées sur les différentes régions de l’œil . . . . .	48
2.2.1	Approches de segmentation supervisée . . . . .	48
2.2.2	Approches de segmentation semi-supervisée . . . . .	53
2.2.3	Approches de segmentation non supervisée . . . . .	58
2.3	Conclusion . . . . .	66
<b>3</b>	<b>Modèles statistiques pour la segmentation</b>	<b>67</b>
3.1	Généralités sur la segmentation bayésienne . . . . .	69
3.1.1	Estimateurs Bayésiens . . . . .	70
3.1.1.1	Maximum a posteriori (MAP) . . . . .	70
3.1.1.2	Mode des Marginales a posteriori (MPM) . . . . .	71
3.1.2	Méthodes d’estimation des paramètres . . . . .	71
3.1.2.1	Espérance-Maximisation (EM) . . . . .	72
3.1.2.2	Espérance-Maximisation Stochastique (SEM) . . . . .	73
3.1.2.3	Estimation Conditionnelle Itérative (ICE) . . . . .	74
3.2	Chaînes Markov Cachées . . . . .	76
3.2.1	Définition du modèle . . . . .	76
3.2.2	Estimation des paramètres d’une HMC . . . . .	77
3.2.3	Restauration d’une HMC . . . . .	78
3.3	Chaînes Markov Couples . . . . .	80
3.3.1	Définition du modèle . . . . .	80
3.3.2	Estimation des paramètres d’une PMC . . . . .	81



3.3.3	Restauration d'une PMC . . . . .	83
3.4	Chaînes Markov Triplets . . . . .	83
3.4.1	Définition du modèle . . . . .	84
3.4.2	Estimation des paramètres . . . . .	85
3.4.3	Restauration des chaînes de Markov triplets . . . . .	87
3.5	Conclusion . . . . .	88
<b>4</b>	<b>Modélisation proposée pour la segmentation non supervisée des images de l'iris</b>	<b>89</b>
4.1	Processus de traitement complet . . . . .	91
4.1.1	Détection grossière de la région de l'iris . . . . .	91
4.1.2	Conception des modèles statistiques pour la segmentation des images de l'iris . . . . .	92
4.2	Impact du parcours de l'image sur la segmentation finale . . . . .	94
4.2.1	Parcours Hilbert-Peano . . . . .	94
4.2.2	Parcours Escargot . . . . .	95
4.2.3	Application sur l'image de l'iris . . . . .	97
4.2.4	Comparaison des segmentations . . . . .	100
4.2.5	Évaluation des cercles de normalisation . . . . .	105
4.3	Impact des Méthodes d'initialisation sur la segmentation finale . . . . .	109
4.3.1	Initialisation par K-means . . . . .	110
4.3.2	Initialisation par Histogramme . . . . .	110
4.3.3	Évaluation des cercles de normalisation . . . . .	112
4.4	Conclusion . . . . .	118
<b>5</b>	<b>Mise en œuvre des chaînes de Markov pour la reconnaissance d'iris</b>	<b>120</b>
5.1	Introduction . . . . .	121
5.2	Estimation de contours et module de reconnaissance . . . . .	122
5.2.1	Localisation automatique de la pupille . . . . .	122
5.2.2	Paramétrisation des contours . . . . .	125

5.2.3	Construction du masque de l'iris . . . . .	126
5.2.4	Modules de reconnaissance . . . . .	128
5.3	Évaluation des Chaînes de Markov pour la reconnaissance de l'iris . . . . .	128
5.3.1	Limitation de la méthode d'initialisation par histogramme . . . . .	128
5.3.2	Évaluation des performances . . . . .	131
5.3.3	Évaluation des temps de calcul . . . . .	135
5.4	Impact du sous échantillonnage sur les performances et les temps de calculs .	136
5.4.1	Sous-échantillonnage de l'image . . . . .	136
5.4.2	Sous-échantillonnage de la chaîne . . . . .	138
5.5	Conclusion . . . . .	140
<b>6</b>	<b>Mise en œuvre de la segmentation des images d'iris en couleur</b>	<b>141</b>
6.1	Introduction . . . . .	142
6.2	Modélisation des chaînes de Markov cachées vectorielles . . . . .	144
6.2.1	Définition des chaînes de Markov cachées vectorielles . . . . .	144
6.2.2	Estimation des paramètres des chaînes de Markov cachées vectorielles	144
6.2.3	Restauration des chaînes de Markov cachées vectorielles . . . . .	146
6.2.4	Conception des chaînes de Markov cachées vectorielles pour la segmen- tation non supervisée de l'iris en couleur . . . . .	146
6.3	Évaluation des Chaînes de Markov pour la segmentation de l'iris en couleur .	146
6.3.1	Segmentation d'une image monospectrale . . . . .	149
6.3.2	Segmentation d'une image multispectrale . . . . .	151
6.3.3	Comparaison avec les méthodes existantes . . . . .	153
6.4	Conclusion . . . . .	155
	<b>Conclusions et perspectives</b>	<b>156</b>

# Liste des acronymes

<b>FR</b>	Faux Rejet
<b>FA</b>	Fausse Acceptation
<b>FRR</b>	Taux de Faux rejets
<b>FAR</b>	Taux de fausses acceptations
<b>EER</b>	Taux d'Erreurs Égales
<b>GAR</b>	Taux d'acceptation de clients
<b>DET</b>	Detection Error Trade-off
<b>ROC</b>	Fonction d'Efficacité du Récepteur
<b>LED</b>	Lampes à Diode Électroluminescente
<b>IDO</b>	Opérateur Intégrodifférentiel
<b>NIR</b>	Near Infrared
<b>MAP</b>	Maximum a posteriori
<b>MPM</b>	Mode des Marginales a posteriori
<b>EM</b>	Espérance-Maximisation
<b>SEM</b>	Espérance-Maximisation Stochastique
<b>ICE</b>	Estimation Conditionnelle Itérative

<b>HMC</b>	Chaîne de Markov Cachée
<b>PMC</b>	Chaîne de Markov Couple
<b>TMC</b>	Chaîne de Markov Triplet
<b>TMC-OSP</b>	Chaîne de Markov Triplet avec une seule stationnarité du bruit de la pupille
<b>HMC_SK</b>	comabinaison HMC, <i>parcours Escargot</i> et Kmeans
<b>HMC_PK</b>	comabinaison HMC, <i>parcours Hilbert-Peano</i> et Kmeans
<b>PMC_SK</b>	comabinaison PMC, <i>parcours Escargot</i> et Kmeans
<b>PMC_PK</b>	comabinaison PMC, <i>parcours Hilbert-Peano</i> et Kmeans
<b>TMC_SK</b>	comabinaison TMC, <i>parcours Escargot</i> et Kmeans
<b>TMC_PK</b>	comabinaison TMC, <i>parcours Hilbert-Peano</i> et Kmeans
<b>TMC-OSP_SK</b>	comabinaison TMC-OSP, <i>parcours Escargot</i> et Kmeans
<b>TMC-OSP_PK</b>	comabinaison HMC-OSP, <i>parcours Hilbert-Peano</i> et Kmeans
<b>HMC_SH</b>	comabinaison HMC, <i>parcours Escargot</i> et histogramme
<b>PMC_SH</b>	comabinaison PMC, <i>parcours Escargot</i> et histogramme
<b>TMC-OSP_SH</b>	comabinaison TMC-SOP, <i>parcours Escargot</i> et histogramme
<b>HMC_SN</b>	comabinaison HMC, Kmeans, <i>parcours Escargot</i> et réseau de neurones

# Introduction générale

LES systèmes de vision par ordinateur évoluent rapidement et occupent une place importante dans notre vie quotidienne. L'expansion de ces systèmes s'explique par l'accroissement permanent des applications dans différents domaines tels que : la télédétection, la médecine, l'automobile, ou encore la sécurité et notamment en biométrie, qui correspond au sujet de ce travail de thèse. Parmi les diverses modalités biométriques, l'iris lorsqu'il est acquis en conditions contrôlées, présente d'excellentes performances, mais ceci au prix de contraintes fortes imposées aux utilisateurs.

Or certaines applications telles que la vidéosurveillance ou le contrôle d'accès dans les aéroports, exigent le relâchement de ces contraintes. Par exemple l'acquisition peut se faire à grande distance et en mouvement. La reconnaissance par l'iris est rendue difficile dans ces conditions à cause des différentes dégradations introduites sur l'image de l'œil. Ces dégradations ont des effets néfastes sur la précision de la segmentation de l'iris dans l'image, première étape de tout processus de reconnaissance qui a un impact très important sur les performances d'identification. Dans ce cadre complexe, il s'agit de concevoir un système capable de segmenter les images dégradées de l'iris en limitant au maximum le nombre d'erreurs possibles.

Plusieurs approches ont été proposées dans la littérature pour cette tâche difficile, toutes empruntées au traitement des images. C'est pourquoi nous consacrons un chapitre de ce manuscrit à une revue de ces techniques. Seuls deux travaux ont montré la possibilité d'utiliser des modèles markoviens basés sur des champs de Markov cachés ou triplets (107) et (13) pour segmenter des images oculaires dégradées. L'utilisation des champs de Markov pour traiter des images est naturelle (62), (16), (101), (47), (18). Cependant, la mise en œuvre de ces modèles et surtout celle du triplet est très complexe et coûteuse en temps de calcul. De nombreuses

d'études ont montré que l'utilisation des chaînes de Markov permet un traitement plus rapide et raisonnable avec une perte d'efficacité, en général, acceptable (14), (58), etc.

Dans cette thèse, notre intérêt porta sur des modèles statistiques avancés, particulièrement sur les chaînes de Markov à savoir les chaînes de Markov cachées, couples, triplets. En effet, ces modèles encore peu exploités pour la biométrie de l'iris, ont prouvé leur efficacité pour résoudre des problèmes inverses et plus particulièrement le problème de segmentation dans différentes applications (27), (26), (31), (50), etc. L'utilisation de ces modèles permet de modéliser les données observables comme une version bruitée de la version segmentée recherchée. Ces modèles, basés sur la théorie bayésienne, permettent l'estimation des paramètres lorsque ces derniers sont inconnus.

L'introduction des chaînes de Markov pour résoudre un problème de segmentation n'est pas récent (108). Ceci dit, au moment du démarrage de cette thèse ces modèles n'avaient pas été exploités pour la segmentation des images dégradées de l'iris et leur potentiel restait donc encore à explorer. En effet, la reconnaissance par l'iris est une application réelle, qui possède des contraintes fortes en terme de temps de réponse et ces modèles Markoviens sont bien connus pour leur grande complexité calculatoire, ce qui explique l'absence des travaux scientifiques antérieurs à cette thèse.

Ainsi, l'objectif général de ce projet de recherche est d'étude de la faisabilité pour la réalisation d'une segmentation non supervisée d'images dégradées de l'iris par des modélisations statistiques markoviennes tout en maintenant des temps de calcul raisonnables, dans un but d'authentification biométrique.

Il nous fallait pour cela résoudre les deux problèmes suivants :

1) Choisir parmi les divers modèles de chaînes disponibles (celui) ceux qui sont les plus adaptés au problème traité. Pour cela il nous a fallu réfléchir à la meilleure façon de les implémenter. Les chaînes se réfèrent à un signal 1D, un des premiers points que nous avons étudiés au cours de cette thèse porte sur la manière de transformer des images modélisées par un signal 2D (nos images de l'œil) en un signal 1D.

Nous avons observé que la méthode de transformation traditionnelle nommée *parcours Hilbert-Peano* exploitée dans la majorité des travaux de la littérature peut s'avérer limitée.

Surtout que, les images de l'iris sont caractérisées par la présence de contours circulaires qui délimitent la région de l'iris. Un parcours (essentiellement horizontal ou vertical) peut apparaître non optimal pour ce genre d'images. Nous avons alors proposé un nouveau parcours de l'image sous forme d'une spirale, plus adapté aux contours circulaires. Nous verrons que cette méthode de transformation de l'image que nous avons nommée *parcours d'Escargot* peut s'avérer efficace dans le cadre de la segmentation non supervisée des images de l'iris.

D'autre part, nous montrerons, grâce à une étude comparative, que le choix de la méthode utilisée pour l'initialisation des paramètres des modèles étudiés, influence positivement ou négativement le résultat, selon le modèle en question. Nous noterons que les chaînes de Markov cachées peuvent améliorer la qualité de la segmentation lorsque l'initialisation est bonne contrairement aux chaînes de Markov couples et triplets auxquelles nous nous sommes intéressés.

2) Évaluer l'apport de ces nouvelles modélisations markoviennes pour la segmentation non supervisée des images dégradées de l'iris par rapport aux approches de l'état de l'art et ceci en terme de performance de reconnaissances.

La plupart des systèmes de vérification par l'iris travaillent sur des images en niveaux de gris, acquises à partir d'images infra-rouge ; c'est en effet de cette manière que l'on peut accéder à l'iris en s'affranchissant de différents artefacts. Classiquement la recherche des contours de l'iris se fait à partir de l'image des gradients calculés sur l'image en niveaux de gris. C'est par exemple ce qui est implémenté dans le système de référence OSIRIS-V4 qui utilise l'algorithme de Viterbi pour déterminer ce contour. Les autres modules d'OSIRIS-V4 qui correspond à un système complet de reconnaissances par l'iris nous serviront tout au long de cette thèse.

Nous proposons dans cette thèse une étape qui consiste à transformer l'image en niveaux de gris en une image de régions, via la segmentation non supervisée par chaîne de Markov. La détermination du contour se fera alors à partir de cette image de région.

Nous avons comparé le système de reconnaissances basé sur cette modélisation des régions, aux approches traditionnelles basées sur la recherche de contours sur l'image niveau de gris ou sur des régions obtenues par des approches supervisées. Notre évaluation, réalisée sur les

bases de données publiques ICE-2005 et CASIA-IrisV4-distance, consiste à étudier les taux de vérification de chaque système.

Le développement de la biométrie sur terminal mobile a remis sur le devant de la scène l'intérêt du traitement de la reconnaissance par l'iris à partir d'images en couleur. Tous les smartphones disposent à l'origine d'au moins une caméra de ce type. La qualité des images est alors très dégradée. Nous avons voulu évaluer dans quelle mesure la méthodologie proposée restait efficace sur ce type d'images. Pour cela nous étendons la modélisation présentée dans le cas monospectral au cas multispectral. Les expériences ont été menées sur la base de test NICE-I, qui sert de benchmark à la communauté. Nous observons que la méthodologie proposée peut s'implémenter dans ce cadre et que le système résultant reste compétitif face aux récentes méthodes proposées pour la segmentation des images de l'iris en couleur.

## Organisation du manuscrit

Le manuscrit de thèse est organisé comme suit :

- **Chapitre 1. Généralités biométriques** : nous introduirons dans ce chapitre les principaux concepts usuels en biométrie. Ensuite, nous décrirons les différents éléments qui constituent un système de reconnaissances de l'iris. Enfin, les bases de données de l'iris ICE-2005, CASIA-IrisV4-distance, UBIRIS-v2 utilisées dans ce travail pour évaluer la modélisation proposée seront décrites à la fin de ce chapitre.
- **Chapitre 2. État de l'art des méthodes de segmentation d'iris** : nous consacrons ce chapitre à l'analyse de l'état de l'art des différentes méthodes proposées dans la littérature pour la segmentation des images dégradées d'iris. En particulier, deux grandes familles de segmentation ont été considérées. La première est basée sur la recherche des contours. La deuxième consiste à rechercher les régions en premier lieu avant la recherche des contours.
- **Chapitre 3. Modèles statistiques pour la segmentation** : nous débuterons ce chapitre par l'introduction des fondements de la classification bayésienne. Nous consacrons



crerons la première partie aux méthodes d'estimation des paramètres ainsi qu'aux méthodes de restauration du processus caché. Dans la deuxième partie, nous décrivons les modèles markoviens : chaîne de Markov cachée, couple, triplet. Une configuration spécifique aux chaînes de Markov triplets et relativement simple en vue du nombre de paramètres à estimer, sera prise en compte dans la suite de ce manuscrit.

- **Chapitre 4. Modélisation proposée pour la segmentation non supervisée des images d'iris :** nous étudierons d'abord dans ce chapitre, la technique usuelle, considérée dans la plupart des cas, pour la linéarisation des images en vue d'utilisation d'une chaîne de Markov. Nous verrons ensuite que cette méthode s'avère limitée pour la linéarisation des images de l'iris. Alors, nous introduirons notre méthode *parcours d'Escargot* pour linéariser l'image. Nous expliquerons par la suite sa mise en œuvre sur les images de l'iris. Enfin, nous étudierons les diverses initialisations possibles des paramètres des modèles statistiques et mesurerons leur impact en fonction des types de chaînes. Ce travail est validé sur une partie de la base ICE-2005 pour laquelle nous disposons d'une réalité terrain.
- **Chapitre 5. Mise en œuvre des chaînes de Markov pour la reconnaissance d'iris :** nous présenterons dans ce chapitre le système de reconnaissances proposé. Nous détaillerons les différents modules qui le constituent. Le système de reconnaissances proposé a été validé sur deux grandes bases de données publiques ICE-2005 et CASIA-IrisV4-distance. Nous réaliserons par la suite une comparaison des performances de reconnaissance entre notre système et les méthodes récentes de l'état de l'art. Enfin, nous verrons comment les taux de vérification de l'iris peuvent être conservés tout en améliorant les temps de calcul.
- **Chapitre 6. Mise en œuvre de la segmentation des images d'iris en couleur :** Nous adapterons la méthodologie proposée dans les chapitres précédents pour la segmentation des images prises en lumière visible. Nous présenterons une extension de cette modélisation aux données multidimensionnelles. L'étude a été réalisée sur la base de test NICE-I qui est extraite de la base UBIRIS-v2. Nous montrerons à travers

les résultats que l'utilisation de notre modélisation pour la segmentation des images en couleur reste possible et offre des perspectives intéressantes.

# Chapitre 1

## Généralités biométriques

---

<b>1.1</b>	<b>Systèmes biométriques</b>	<b>12</b>
<b>1.2</b>	<b>Évaluation des performances des systèmes biométriques</b>	<b>14</b>
1.2.1	Les mesures des taux d'erreurs	15
1.2.2	Les courbes de performances	16
1.2.3	Les points de fonctionnement	17
<b>1.3</b>	<b>Système de reconnaissance de l'iris</b>	<b>18</b>
1.3.1	Module d'acquisition d'images d'iris	20
1.3.2	Module de reconnaissance de l'iris	26
<b>1.4</b>	<b>Base de données de l'iris</b>	<b>30</b>
1.4.1	ICE2005	30
1.4.2	CASIA-IrisV4-distance	31
1.4.3	UBIRIS	32

---

**A**UJOURD'HUI, la biométrie à grande échelle est une réalité. Elle est considérée comme un aboutissement révolutionnaire suite au développement rapide des technologies. Contrairement aux mots de passe, utilisés dans plusieurs situations pour la protection de la vie privée, qui présentent plusieurs failles, la biométrie s'impose comme un moyen avantageux, intéressant et fort pour la sécurisation de la vie humaine soit en publique ou en privé.

La biométrie vise à établir une reconnaissance automatique des personnes à partir de leurs caractéristiques morphologiques tels que : l'iris, la rétine, l'empreinte digitale, le visage, le réseau veineux, la forme des mains, etc. ou biologiques tels que le sang, la salive, l'urine, l'ADN, les cheveux, etc. ou encore comportementales telles que la voix, la dynamique de la signature, de l'écriture et de la frappe, etc. Toutes ces propriétés humaines représentent des caractéristiques propres à chaque individu (41), (70).

Afin que ces propriétés humaines (biologiques, morphologique ou comportementales) soient considérées comme des modalités biométriques, elles doivent répondre aux différents critères suivants (41), (70) :

- **Universalité** : chaque individu doit posséder la modalité.
- **Unicité** : la modalité doit être exclusive pour chaque individu.
- **Permanence** : la modalité doit être suffisamment stable et ne doit pas être trop modifiée en fonction du temps.
- **Collectabilité** : la modalité doit être facile à mesurer (numériser) et à collecter dans n'importe quelle situation. Attention, la collection doit être confidentielle.
- **Performance** : la modalité doit assurer de bonnes précisions de reconnaissance.
- **Acceptabilité** : les usagers ciblés doivent accepter, en terme du protocole d'acquisition, la modalité biométrique dans leur vie quotidienne.
- **Contournement** : la modalité doit être idéalement non falsifiable, pour rassurer la *sécurité* du système biométrique.

La figure 1.1 montre quelques exemples des différentes modalités biométriques. Il est important de préciser que les différentes modalités biométriques ne satisfont pas complètement les différents critères cités auparavant. Ces critères vont faciliter le choix de la modalité la plus avantageuse selon l'application visée.

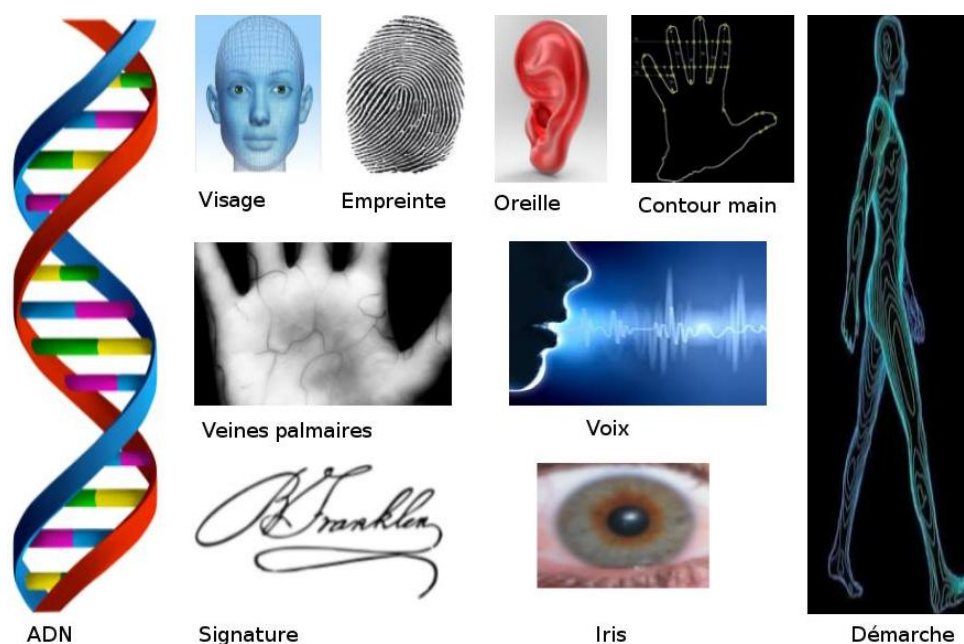


FIGURE 1.1 – Différentes modalités biométriques.

Avec la biométrie, une gigantesque révolution technologique est en marche. Les chercheurs et les industriels ont mis à la disposition des utilisateurs plusieurs applications (Figure 1.2), qui touchent principalement trois domaines :

- Légal : qui englobe tous les problèmes liés à la justice (identification des corps, des criminels, etc) .
- Gouvernemental : qui vise à contrôler les documents d'identités et le transit entre les frontières, etc.
- Commercial : qui permet la sécurisation des smartphones et des ordinateurs (accès aux différentes applications, informations confidentielles, identifiant, etc.), des sites sensibles

(laboratoires, industries, bâtiments, etc), des transactions bancaires et des paiements en ligne (e-commerce).



FIGURE 1.2 – Exemples d’applications biométriques.

Dans les sections 1.1 et 1.2, nous aborderons des connaissances globales et importantes sur les systèmes biométriques qui seront adoptées dans les différents chapitres de ce rapport de thèse. La Section 1.3 est consacrée à une description brève d’un système automatique de reconnaissance de l’iris. C’est le sujet de ce travail. Nous nous focaliserons dans la Section 1.4 sur la présentation des différentes bases de données utilisées pour l’évaluation de nos approches.

## 1.1 Systèmes biométriques

Avec l'augmentation de la population mondiale, la sécurité de la vie humaine est devenue une priorité dans la plupart des pays développés et même dans quelques pays en voie de développement. L'appel à des systèmes automatiques de reconnaissance biométrique peut être considéré comme une solution fiable aux différents problèmes liés aux domaines de justice, de transit international et aux transactions bancaires, etc.

Tous les systèmes biométriques, quelle que soit la modalité utilisée, se composent de deux phases principales : phase d'enrôlement et phase de test ou reconnaissance. La phase d'enrôlement consiste à acquérir les données par des capteurs spécifiques (Figure 1.3), permettant la transformation des modalités réelles en données numérisées sous forme d'images, signaux, etc. et à enregistrer ces données numérisées sur des supports physiques. La phase de reconnaissance (Figure 1.4) permet de traiter ces données et d'extraire les caractéristiques discriminantes et pour produire un gabarit (template en anglais) qui sera utilisé dans la phase de comparaison. Cette dernière consiste à comparer le gabarit aux différents gabarits références enregistrés dans la base de données lors de la procédure d'enrôlement.



FIGURE 1.3 – Acquisition de données avec quelques exemples de capteurs biométriques.

Selon l'application ciblée, le système biométrique fonctionne en mode vérification (authentification) ou en mode identification (70).

- **Le mode de vérification** vise à mettre en correspondance le gabarit test avec l'un des gabarits enregistrés dans la base de données et tente de répondre à la question : Êtes vous la personne que vous prétendez être ? Dans ce fonctionnement, le système biométrique réalise une comparaison de type *un-à-un*, où le gabarit test est comparé à un gabarit de référence. La mise en correspondance entre les gabarits est quantifiée par un score de similarité (ou dissimilarité). Ce score de comparaison sera comparé à un seuil prédéfini pour prendre une décision d'acceptation ou de rejet.
- **Le mode d'identification** vise à reconnaître l'identité du gabarit de test dans le but de répondre à la question : Qui êtes vous ? Le système biométrique fait appel à des comparaisons de type *un-à-N* ( $N$  le nombre des gabarits enregistrés), où le gabarit de test est comparé à tous les gabarits stockés de toutes les personnes. Dans ce cas, le système propose une liste des personnes les plus probables.

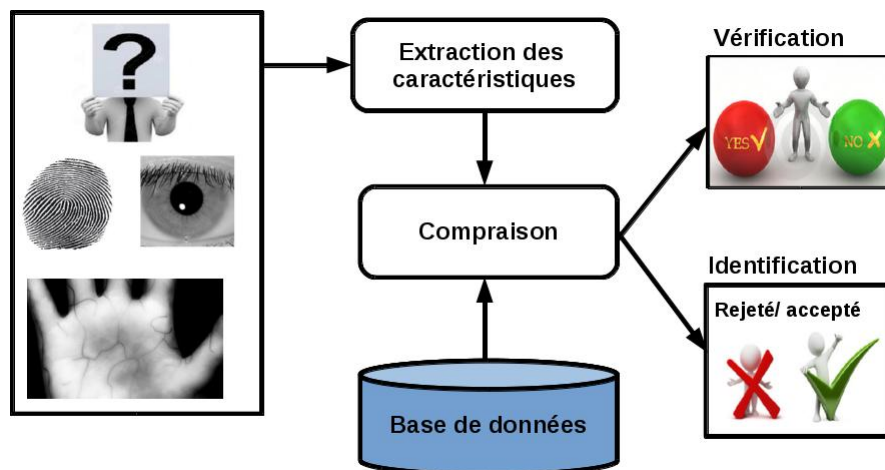


FIGURE 1.4 – Module de reconnaissance d'un système biométrique.



## 1.2 Évaluation des performances des systèmes biométriques

Face aux différentes applications basées sur des systèmes de reconnaissance biométrique proposées pour faciliter la vie quotidienne, l'utilisateur doit être capable de choisir la meilleure application qui répond à ses besoins (facile à utiliser, économique, de bon niveau de protection des données, la plus performante, etc.). Pour aider l'utilisateur à choisir l'application appropriée, les auteurs de (95) ont proposé les évaluations suivantes :

- **Évaluation de la technologie** : vise à tester l'efficacité des algorithmes sur des bases de données enregistrées.
- **Évaluation du scénario** : vise à évaluer un système biométrique complet (capteurs + algorithmes).
- **Évaluation opérationnelle** : vise à mesurer les performances d'un système complet dans des conditions réelles.

Dans la suite de ce document, lorsque nous évoquerons l'évaluation des systèmes biométriques, nous ne ferons que de l'évaluation technologique. Nous testerons les différentes approches étudiées sur des bases de données pré-acquises dans des conditions non contrôlées. Nous avons cité précédemment qu'il existe deux modes opérationnels des systèmes biométriques. Dans ce travail, nous nous intéressons au mode de vérification.

En mode vérification, nous considérons à la fois les comparaisons clients et les comparaisons imposteurs. Les comparaisons clients sont des comparaisons entre les échantillons de la même personne. Les comparaisons imposteurs sont des comparaisons entre les échantillons personnes différentes. Pour évaluer les performances d'un système de reconnaissance biométrique, nous effectuons des comparaisons de type *un-à-un* c-à-d toutes les comparaisons possibles entre les différents échantillons de la base de données. Chaque comparaison est associée à un score de dissimilitude. L'ensemble des scores génère la distribution des clients et celle des imposteurs. Si ces deux distributions sont bien séparées (aucun chevauchement), le système biométrique est alors dit idéal. Dans le cas réel, les deux distributions se recouvrent (Figure : 1.5).

La décision d'acceptation ou de rejet est liée à un seuil. Quel que soit le seuil, des erreurs sont engendrées. Ces erreurs sont considérées comme une mesure d'évaluation. Il existe deux types d'erreurs :

- **Faux Rejet (FR)** : dans le cas où le système considère un client comme un imposteur.
- **Fausse Acceptation (FA)** : dans le cas où le système considère un imposteur comme un client.

À partir de ces deux types d'erreurs (FR et FA), l'évaluation est basée sur différentes métriques.

### 1.2.1 Les mesures des taux d'erreurs

L'accumulation des erreurs lors de l'évaluation d'un système biométrique permet de calculer les taux d'erreurs à un seuil fixé (95).

- **Taux de fausses acceptations (FAR)** : en anglais False Acceptance Rate, c'est le pourcentage de comparaisons d'imposteurs qui ont été acceptées.
- **Taux de Faux rejets (FRR)** : en anglais False Rejection Rate, c'est le pourcentage de comparaisons clients qui ont été rejetées.
- **Taux d'acceptation de clients (GAR)** : en anglais Genuine Acceptance Rate, c'est défini comme :  $GAR = 1 - FRR$ .

Ces mesures sont utilisées pour comparer les performances des différents systèmes de reconnaissance biométrique. Ces taux d'erreurs (FAR et FRR) dépendent du choix de la valeur du seuil de décision. Si le FAR est faible (les imposteurs auront des difficultés à pénétrer) et le FRR est élevé (les clients pourront entrer mais avec difficulté) alors le système biométrique est de **haute sécurité**. Dans le cas inverse, le système est **permissif** (faible sécurité).

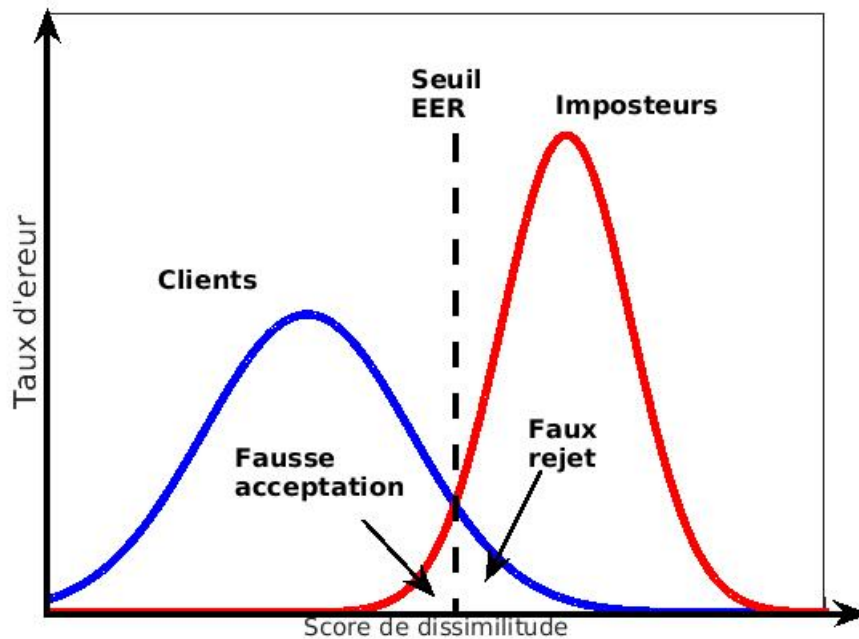


FIGURE 1.5 – Densités de scores de dissimilitude d'un système biométrique réel.

### 1.2.2 Les courbes de performances

La variation de la valeur du seuil de décision permet de représenter les changements des différentes métriques FAR, FRR et GAR. Nous nous basons sur ces dernières pour définir les courbes de performances (95) qui permettent de visualiser la variation des performances d'un système biométrique en fonction du seuil :

- **Courbe des densités de scores** : représente la distribution des clients et imposteurs en fonction des scores de dissimilitude (Figure 1.5).
- **Courbe DET (Detection Error Trade-off)** : exprime la variation de FRR en fonction de FAR (ou FAR en fonction de FRR) (figure 1.6(a)). Chaque point dans la courbe est lié à un seuil de décision.
- **Courbe ROC (Receiver Operating Characteristic)** : indique la variation de GAR

en fonction de FAR (figure 1.6(b)).

Il est à noter qu'il est possible d'utiliser l'échelle logarithmique sur les deux axes (ou sur juste un seul) des courbes DET et ROC. Ce passage facilite la détection des points de fonctionnement qui seront définis dans la sous section suivante.

### 1.2.3 Les points de fonctionnement

Selon l'application ciblée, un seuil de décision doit être fixé pour prendre des décisions d'acceptation ou de rejet. Par conséquent, une indication des performances du système à cette valeur de seuil est donnée. Cette situation présente le choix du point de fonctionnement du système.

Pour évaluer les systèmes biométriques, trois points de fonctionnement sont principalement utilisés :

- **Taux d'Erreurs Égales (EER)** : en anglais Equal Error Rate, est calculé à la valeur du seuil de décision où FAR et FFR sont égaux.
- **FAR fixé** : lors de l'utilisation de ce point de fonctionnement, la performance du système biométrique est donnée par une valeur de FRR à un taux de FAR (respectivement GAR) précis.
- **FRR (respectivement GAR) fixé** : la performance du système à ce point de fonctionnement est exprimée par la valeur du FAR.

Dans la suite de ce rapport, nous nous intéresserons aux applications de sécurité. Donc, nous choisissons d'utiliser les points de fonctionnement suivants : EER, FAR fixé à  $10^{-3}$  et FAR fixé à  $10^{-4}$ . Ils sont considérés par la communauté scientifique comme les indicateurs les plus pertinents lors de l'évaluation de l'efficacité des systèmes biométriques dans un but d'application de sécurité. Le FAR fixé est exprimé par le GAR correspondant. Nous utilisons la courbe ROC pour visualiser l'évolution des performances.

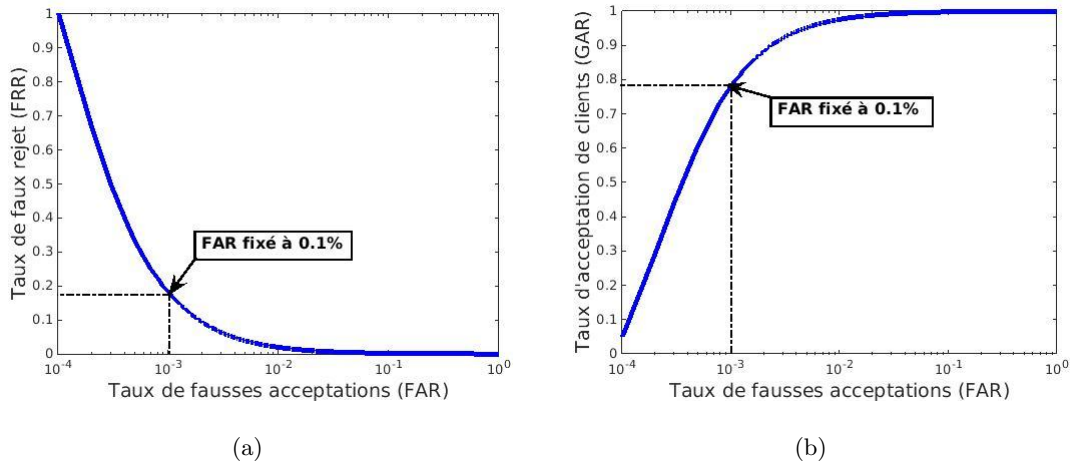



FIGURE 1.6 – Courbe DET (a) et Courbe ROC (b).

### 1.3 Système de reconnaissance de l'iris


Dans la section précédente, nous avons donné un aperçu général des systèmes biométriques et de leur évaluations. Nous précisons que ce travail s'intéresse aux problèmes de reconnaissance des personnes par l'iris. L'iris est une structure annulaire, visible et colorée dans le globe oculaire. Cette structure est représentée par une membrane contractile riche en texture qui permet la régularisation de la dilatation de la pupille en fonction de la lumière pénétrée. L'iris est localisé entre la pupille et le blanc de l'œil (sclera) (114). La mélanine est le pigment principal responsable de la coloration de l'iris. Toute modification locale de la concentration de la mélanine provoque une hétérochromie (différence de couleur entre les parties d'un iris ou entre les deux iris). La figure 1.7(a) illustre la localisation de l'iris par rapport aux différentes structures de l'œil humain. Un schéma de l'iris humain est représenté dans la figure 1.7(b).

L'iris est un organe interne bien protégé par la cornée donc non exposé aux lésions. Ceci permet à l'iris d'être une modalité biométrique fiable par rapport à d'autres modalités tels que le visage et l'empreinte digitale. Il satisfait la majorité des critères exigés tels que : l'universalité, la permanence et l'unicité. En plus de sa stabilité durant toute la vie humaine, l'iris est de grande complexité grâce à la richesse et aux détails de sa texture (7). Ces motifs

texturaux sont de fortes variabilités et ils engendrent une faible probabilité de similitude ( $\approx 10^{-72}$ ) entre deux personnes (même entre les jumeaux) (43).



(a)



(b)

FIGURE 1.7 – Vue frontale de l'oeil humain (a) et l'iris humain (b) (1).

L'iris est introduit pour la première fois comme un concept de reconnaissance de personnes en 1886 par Alphonse Bertillon qui ne s'intéressa cependant qu'à la couleur des yeux pour prendre une décision d'identification (15). L'idée d'utiliser l'iris pour reconnaître les personnes a été proposée en 1986 par Leanoard Flom et Aran Safir qui considèrent que la texture de l'iris est un bon motif d'identification de personnes (76). En 1994, John Daugman a concrétisé cette idée et a proposé un système automatique de reconnaissance de l'iris (44). Il a détaillé les différents modules du système dans son travail (43). Actuellement, la plupart des systèmes de reconnaissance sont basés sur l'approche proposée par Daugman. Le système est composé de deux modules : module d'acquisition d'images des yeux et module de reconnaissance de l'iris. Ces deux modules seront décrits dans les sous-sections 1.3.1 et 1.3.2.

### 1.3.1 Module d'acquisition d'images d'iris

Il ressort de la littérature et de l'expérience qu'une bonne qualité des images de l'iris est exigée lors de l'acquisition pour le bon fonctionnement des systèmes de reconnaissances de l'iris. Par ailleurs, l'iris est un petit objet difficile à localiser dans le visage d'où la nécessité d'utiliser des instruments très puissants, très proches de l'individu lors de l'acquisition. Sa localisation derrière la cornée en fait un objet réfléchissant lors de l'utilisation de la lumière pour le visualiser et donc il sera couvert de reflets lumineux. Pour remédier à ce problème, la lumière proche infrarouge (NIR) est préconisée pour l'acquisition des images de l'iris. En plus, l'acquisition impose une forte coopération de la personne. Par conséquent, l'acquisition est faite dans **des conditions contrôlées** (1.3.1.1). Ces dernières années, une nouvelle tendance vers une acquisition dans **des conditions non contrôlées** (1.3.1.2) a vu le jour pour alléger les contraintes imposées de manière à les rendre plus acceptables.

#### 1.3.1.1 Acquisition d'images dans des conditions contrôlées

La plupart des systèmes traditionnels de reconnaissance de l'iris imposent une coopération importante de l'individu lors de l'acquisition. Selon les auteurs du rapport IREX-5 (109), le diamètre de l'iris d'une image de bonne qualité est égal au moins à 160 pixels. Ils recommandent que l'environnement de capture soit bien illuminé. Il faut veiller que toutes les lampes

à diode électroluminescentes (LED), utilisées pour illuminer l'environnement, émettent de la lumière. Avant la capture, il faut s'assurer que l'individu est fixé à distance proche (une distance entre 30 cm et 100 cm), en face et regarde directement la caméra. L'œil est obligatoirement bien ouvert. Lors de la capture, la caméra doit être en face du visage de l'individu et sans aucun obstacle. Après la capture, l'iris doit être présent dans l'image, nécessairement centré, avec un bon contraste, pas d'occlusion de la pupille par les paupières supérieures, bien illuminé avec un maximum de 15° de rotation (liée au mouvement de la tête). La figure 1.8 illustre un exemple d'une image de bonne qualité d'un œil acquise en respectant l'ensemble des recommandations citées auparavant.




FIGURE 1.8 – Exemple d'une image de bonne qualité d'un œil acquise dans des conditions contrôlées (109).



### 1.3.1.2 Acquisition d'image dans des conditions non contrôlées

Le relâchement des contraintes imposées lors de l'acquisition est devenu nécessaire pour rendre l'acquisition plus flexible et dans différents environnements. Autrement dit, il s'agit d'acquérir des images d'un œil d'un individu relativement en mouvement (69), à distance en NIR (32), ou d'utiliser de la lumière visible au lieu de la lumière NIR (102),(106). De ce fait, selon le degré de liberté de l'acquisition, plusieurs facteurs indésirables sont introduits engendrant une dégradation de la qualité des images de l'iris.

- **Dégradations lors de l'acquisition en lumière NIR**

Dans (109), les facteurs indésirables (voir Figure 1.9) ont été résumés en trois catégories. La première est, liée à la personne qui effectue l'acquisition, englobe le bruit de mouvement de la caméra, la rotation de l'iris dans l'image (qui peut résulter du mouvement de l'individu). La deuxième catégorie, liée au comportement de l'individu, contient les occlusions par les paupières et les cils, les reflets lumineux liés aux lunettes, off-angle (iris non centré) et forte dilatation ou contraction de la pupille. La dernière catégorie, liée à la caméra d'acquisition, renferme le bruit de focus, l'absence de l'iris dans l'image, l'illumination irrégulière, le faible contraste pupille/iris ou iris/sclera.

- **Dégradations lors de l'acquisition en lumière visible**

L'acquisition des images oculaires en NIR doit être effectuée avec précaution afin d'éviter toutes sorte de lésions possibles, car l'œil humain n'est pas sensible à l'illumination NIR et ne peut pas utiliser ses mécanismes de défenses naturels tels que le clignement. En revanche, le spectre visible peut être capté par l'œil humain sans aucune limitation. Cela peut offrir un environnement de capture plus flexible. La qualité des images acquises dans ces environnements est dégradée par rapport à celles acquises dans un environnement en utilisant la lumière NIR.

Les facteurs indésirables cités dans le cas des images en NIR, tels que la variation d'illumination, faible contraste, les occlusions par des lunettes, les réflexions, se révèlent plus importantes et plus sévères dans les images en couleur acquises en lumière visible. De ce fait,

on constate une dégradation considérable de la qualité de la texture de l'iris. La figure 1.10 est un exemple de plusieurs images dégradées acquises à distance en utilisant la lumière visible dans des environnements plus flexibles.

La détection en premier lieu du contour pupille/iris dans les images acquises en NIR est considérée comme le processus naturel de toutes les méthodes de segmentation de l'iris décrites dans la littérature par ce que la pupille est la région la plus sombre dans l'image oculaire. En revanche, dans le cas des images en couleur, la pupille ne représente pas toujours la composante la plus sombre à cause des importantes réflexions. En plus, pour les yeux de couleur foncée, le principal problème est le très faible contraste pupille/iris. Par conséquent, la segmentation devient difficile voire impossible.

Quel que soit le mode d'acquisition, les facteurs indésirables ont un effet négatif sur la reconnaissance de l'iris et spécifiquement sur la segmentation d'iris. Il est reporté dans (104) que de petites erreurs de l'estimation des paramètres des cercles (**erreur de segmentation**) modifient l'image normalisée de l'iris produite par le module de normalisation (sous-section 1.3.2.2) et ceci peut diminuer fortement les performances de reconnaissance.

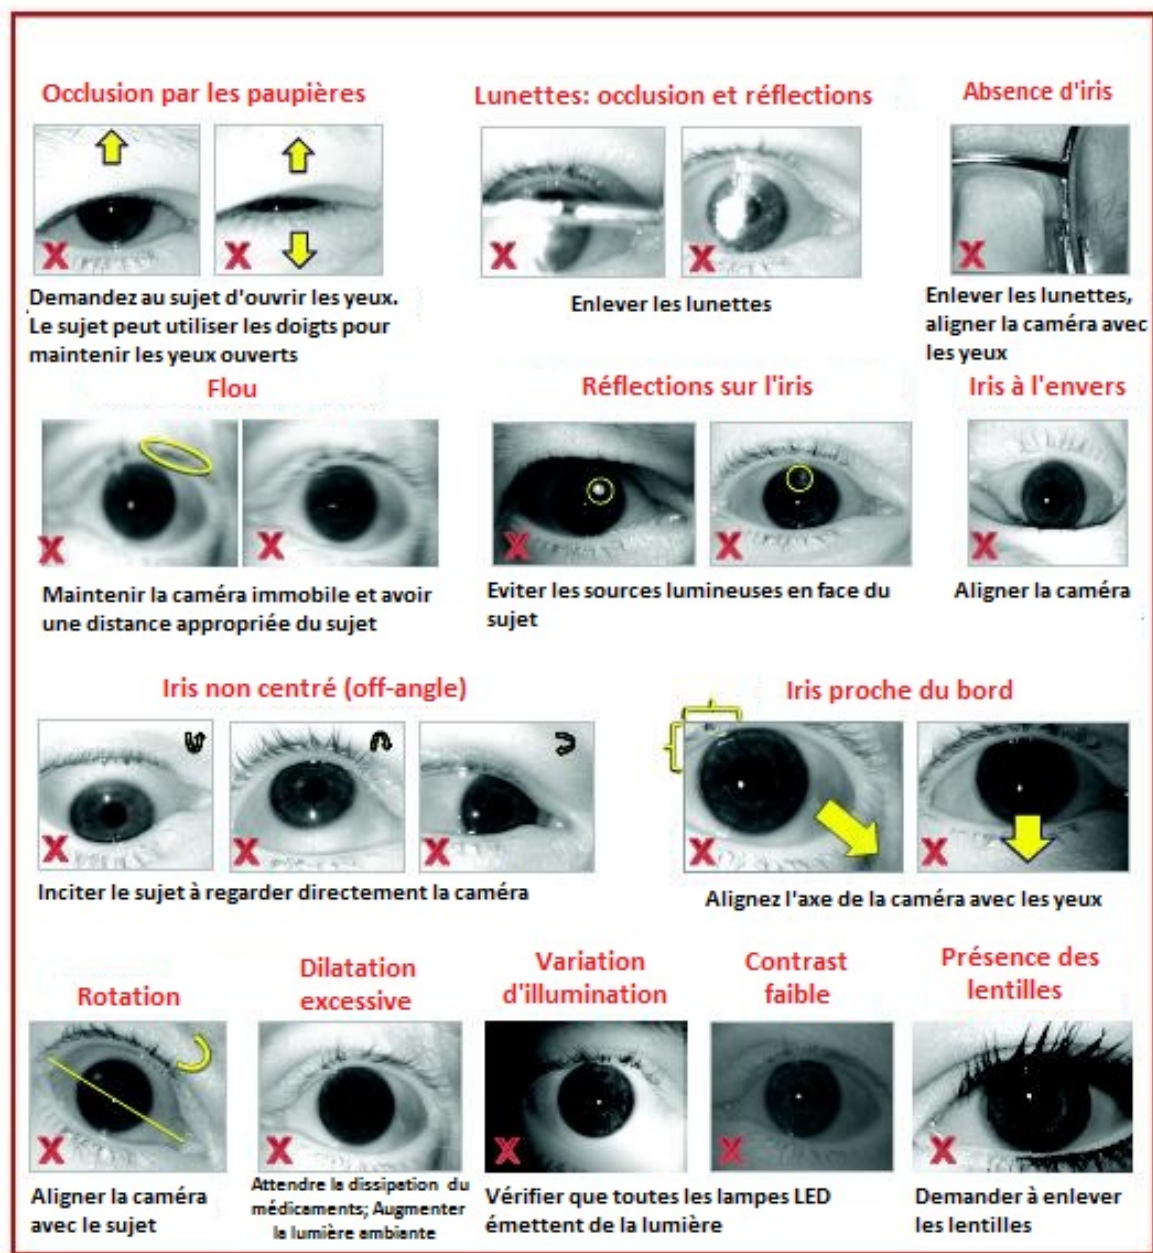


FIGURE 1.9 – Exemples d’images dégradées d’iris acquise en NIR (109), les dégradations peuvent ne pas bien apparaître à cause de la compression d’images.



FIGURE 1.10 – Exemples d’images dégradées d’iris acquise en lumière visible.

### 1.3.2 Module de reconnaissance de l'iris

Une fois que l'image de l'œil est acquise, elle peut être utilisée pour la reconnaissance. Elle doit subir les différentes étapes communes de la plupart des systèmes de reconnaissance de l'iris.

#### 1.3.2.1 Segmentation de l'iris

Le module de segmentation de l'iris consiste à séparer la région de l'iris des autres composantes de l'image de l'œil (cils, sourcils, paupières, etc.). Le problème revient à déterminer les frontières pupille/iris et iris/sclera, qui seront ensuite approchées par des contours paramétrés (figure 1.11(a)) pour faciliter l'étape de normalisation ultérieurement. De plus, il faut identifier les différents pixels appartenant à la texture de l'iris et isoler tous les pixels représentant les différents artefacts. Par conséquent, un *masque d'iris* est généré (Figure 1.11(b)). Plusieurs méthodes ont été proposées pour segmenter les images des yeux. Nous présentons quelques méthodes récentes dans le chapitre 2.

#### 1.3.2.2 Normalisation de l'iris

L'iris est un organe contractile permettant le contrôle de la pénétration de la lumière engendrant une dilatation ou une contraction de la pupille. Pour permettre une comparaison de deux iris, il est donc nécessaire de normaliser à une taille fixe les iris détectés (Figure 1.12). Pour cela, il s'agit de transformer la région de l'iris caractérisée par des contours paramétrés en une bande de taille invariante. Daugman (43) a proposé d'utiliser la transformation *rubbersheet* afin d'effectuer le passage d'un système cartésien à un système pseudo-polaire. Cette représentation permet de construire une image normalisée de l'iris de taille invariante, permettant donc de bien comparer les zones homologues de deux différents iris lors de la mise en correspondance. Malgré le nombre important de méthodes publiées pour améliorer la reconnaissance de l'iris, la plupart utilisent la transformation *rubbersheet* pour normaliser l'iris. Les différences entre ces méthodes proviennent de la façon dont les contours sont paramétrés. Ces contours peuvent être décrits par des formes géométriques simple (cercle, ellipse) ou des

modèles plus généraux (série de Fourier ou des splines).




FIGURE 1.11 – Exemple de la segmentation d’une image d’iris : Frontières de l’iris (a) Masque de l’iris (b).




FIGURE 1.12 – Illustration de la tâche du module de normalisation d’iris : normalisation (a), transformation rubbersheet (b) (113).

### 1.3.2.3 Extraction des caractéristiques

Le but de cette étape est d’extraire une représentation caractéristique et discriminante de l’iris et de produire un gabarit permettant la vérification dans l’étape de comparaison des

motifs. En général, les principales méthodes existantes dans la littérature utilisent le filtre 1D Log-Gabor (83), (132), (128), (128), le filtre 2D Gabor (43), (45), (46), (92) ou la transformée en ondelettes (19), (118), (126), la transformée en cosinus discrète (89). Une étude comparative des différents filtres d'extraction des caractéristiques de l'iris reportés dans la littérature a été proposée par (113) pour identifier leurs impacts sur la reconnaissance de l'iris. Cette étude a montré que le filtre de Gabor permet d'obtenir les meilleures performances de reconnaissance. Le filtre de Gabor peut être appliqué à des points déterminés de l'image normalisée de l'iris à différentes échelles et orientations. Ce filtre fournit des réponses en phase et en module. Ensuite, seule la réponse en phase est quantifiée en une série de bits pour construire un code binaire appelé *iris code*. Lors de la quantification, seulement le quadrant de la phase est considéré pour coder l'information de phase en deux bits afin de compresser cette information.

#### 1.3.2.4 Comparaison des motifs

La reconnaissance de l'iris implique la mise en correspondance entre deux *iris code*. Un score de dissimilitude est calculé pour caractériser le degré de ressemblance ou non entre deux *iris code*. Daugman (43) mesure la différence entre deux *iris codes* par le calcul de la distance de Hamming (Voir Equation 1.1). Cette distance est exprimée par l'opérateur « *ou exclusif* » noté  $\otimes$  et l'opérateur logique « *et* » noté  $\cap$ . Ce score de dissimilitude représente le nombre de bits non masqués différents entre les deux *iris codes* normalisé par le nombre de bits non masqué commun des deux *iris codes*.

$$HD = \frac{\|(IrisCodeA \otimes IrisCodeB) \cap maskA \cap maskB\|}{\|maskA \cap maskB\|} \quad (1.1)$$

Un mouvement de la tête provoque une rotation de l'iris dans l'image originale qui se traduit par une translation dans l'image normalisée. De ce fait, les deux *iris codes* ne sont plus alignés et par conséquent le score résultant de l'équation 1.1 n'est plus significatif. Pour répondre à cette limitation, une translation de *iris code* est appliquée lors de la comparaison (Figure 1.14) dans le but de tolérer une légère rotation et de produire la valeur de la distance de Hamming la plus petite qui correspond à l'alignement le plus convenable (43).

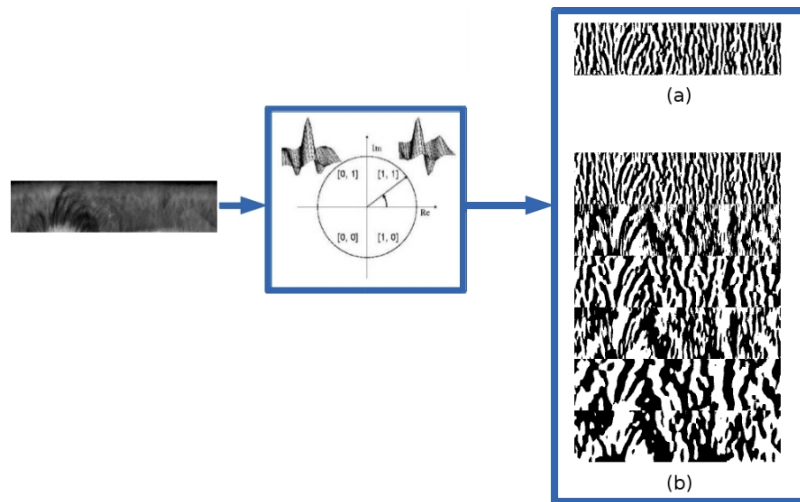


FIGURE 1.13 – Génération de l’iris code par le filtre 2D Gabor : une seule échelle (a), différentes échelles (b).




FIGURE 1.14 – Comparaison d’iris codes avec translation circulaire (112).



## 1.4 Base de données de l'iris

À ce jour, plusieurs bases de données de l'iris sont publiques et partagées par plusieurs équipes de recherche afin de permettre l'évaluation de nouvelles approches de reconnaissance de l'iris par rapport aux méthodes existantes, déjà publiées. Ces bases de données sont particulières et différentes entre elles. Chacune de ces bases a ses propres caractéristiques, qui dépendent de l'environnement, des contraintes d'acquisition ainsi que du capteur utilisé. Dans ce travail, nous nous intéressons particulièrement aux images de l'iris dites difficiles, pour lesquelles, les méthodes de segmentation connues ne donnent pas de résultats satisfaisants. Nous choisissons d'utiliser les bases ICE-2005, CASIA-IrisV4-distance, UBIRIS-v2. Les images de ces bases ont été prises dans des conditions non contrôlées à différentes distances et par des capteurs différents. Elles sont d'une qualité dégradée et souffrent de plusieurs facteurs indésirables tels que la variation d'illumination, le faible contraste, les réflexions spéculaires, le flou, les occlusions, etc. Face à cette multiplicité de cas de figure, nous pouvons évaluer la robustesse de l'approche proposée en fonction de ces différents problèmes. Les images de l'iris de la base ICE-2005 sont d'une haute résolution, celles de CASIA-IrisV4-distance ont une résolution moyenne, cependant les images de UBIRIS-v2 sont de résolution faible. Le choix de ces trois bases nous permettra de valider les résultats de segmentation de notre approche dans différentes conditions.

### 1.4.1 ICE2005

La base de données ICE2005 (69) publiée par le NIST (National Institute of Standards and Technology) a été établie en 2005 spécialement pour une évaluation à grande échelle des systèmes de reconnaissance de l'iris sur des images dégradées de l'iris. Ces images ont été acquises par une caméra dédiée LG2200. La base ICE2005 est composée de 2953 images en niveaux de gris de 132 personnes en deux sessions. La résolution des images est de 480\*640 et le diamètre de l'iris est entre 180 et 280 pixels. Cette base est divisée en deux sous-bases. La première comporte les images de l'iris droit représentant 124 personnes et 1425 images. La deuxième comporte les images de l'iris gauche représentant 120 personnes et 1528 images.

Les différentes images de l'iris droit ou gauche sont acquises en même temps. Cette base de données contient une large variété de facteurs indésirés tels que : les reflets lumineux (spots), le flou, le faible contraste, l'entrelacement, la variation lumineuse et les occlusions par les cils ou les paupières. La figure 1.15 montre quelques exemples d'images de cette base de données.



FIGURE 1.15 – Exemples d'images de la base ICE2005.

#### 1.4.2 CASIA-IrisV4-distance

La base de données CASIA-IrisV4-distance a été construite par CASIA (Chinese Academy of Sciences Institute of Automation) (32). Cette base de données contient des images d'iris capturées en NIR, sans aucune contrainte et avec un minimum de coopération des personnes, à une distance de 3 mètres avec une caméra de haute résolution permettant l'exploitation de la région de l'iris pour un but d'identification. Chaque image assure la présence du visage et des deux yeux dans le but d'évaluer les fusions multi-modales. La résolution des images est

de 2352\*1728 et le diamètre de l'iris dans ces images est entre 124 et 188 pixels. Cette base est composée de 2567 images en niveaux de gris qui représentent 142 personnes. Les images de cette base de données souffrent de plusieurs artefacts tels que la dilatation de la pupille, l'off-angle, les larges réflexions lumineuses, le faible contraste, les larges occlusions par les paupières, les cils, les cheveux et les lunettes, etc. (Voir Figure 1.16).




FIGURE 1.16 – Exemples d'images de la base CASIA-IrisV4-distance.

### 1.4.3 UBIRIS

La base de données UBIRIS (2) publiée par SOCIA Lab (Soft Computing and Image Analysis Group of the University of Beira Interior, Portugal) a été établie en 2004 dans le but d'évaluer les images prises dans des conditions non contrôlées. La particularité de cette base de données est que les images sont acquises en visible contrairement aux bases de données habituelles qui sont acquises en NIR. Au départ, cette base de donnée est nommée UBIRIS-v1 (102) et représentée par 1877 images collectées en deux sessions représentant 261 sujets. Plusieurs facteurs indésirables lors de l'acquisition ont été introduits engendrant un faible contraste, une variation de luminosité, de larges réflexions, différents types d'occlusion

et d'off-angle. Par la suite, cette base de données a été élargie dans un but de créer une large base de données publique pour l'évaluation des systèmes de reconnaissance d'iris acquis en visible. Cette nouvelle base nommée UBIRIS-v2 (106) contient au total 11102 images de résolution 300\*400, représentant 500 sujets de différentes origines mondiales (70 pays). UBIRIS-v2 est acquise à distance (entre 4 et 8 mètres) et le sujet est en mouvement, engendrant différentes résolutions du diamètre de l'iris, dégradation de la qualité texturale de l'iris et les facteurs indésirables cités auparavant vont être amplifiés dans ce cas. La figure 1.17 présente un exemple d'images de trois sujets.



FIGURE 1.17 – Exemples d'images de la base UBIRIS-v2. De gauche à droite : distance d'acquisition en mètres(4,5,6,7,8).

La table 1.1 résume les différentes caractéristiques des trois bases de données citées ci-dessus. En plus, nous reportons les différentes dégradations citées dans (113).

TABLE 1.1 – Comparaison des caractéristiques des bases de données

Bases de données		ICE2005	CASIA-IrisV4- Distance	UBIRIS-v2
Capteur d'acquisition		LG2200	CASIA long-range iris	Canon EOS 5D
Illumination		NIR	NIR	visible
Distance d'acquisition en mètre		< 3	$\geq 3$	4 – 8
Type d'images		oeil	visage	péριο-oculaire
Résolution d'image		640 × 480	2352 × 1728	400 × 300
Résolution d'iris (Diamètre)		180 – 280	124 – 188	90 – 195
Dégradations	Occlusions	++	++	++
	Réflexions	+	++	++
	Variation d'illumination	+	+	++
	off-angle	+	+	++
	effet flou	+		+

Dans le chapitre suivant, nous exposerons les différentes approches récentes proposées dans la littérature pour la segmentation de l'iris. Une analyse des méthodes basées sur la recherche de contours est présentée. Nous nous intéresserons aussi aux approches de recherche de régions et plus particulièrement aux méthodes statistiques.

## Chapitre 2

# État de l'art des méthodes de segmentation de l'iris

---

<b>2.1</b>	<b>Approches basées sur la forme des contours de l'œil</b>	<b>37</b>
2.1.1	Approches basées sur l'opérateur intégrodifférentiel	37
2.1.2	Approches basées sur la transformée de Hough	39
2.1.3	Autres approches	41
2.1.4	Limitations des approches basées sur la forme des contours de l'œil	46
<b>2.2</b>	<b>Approches basées sur les différentes régions de l'œil</b>	<b>48</b>
2.2.1	Approches de segmentation supervisée	48
2.2.2	Approches de segmentation semi-supervisée	53
2.2.3	Approches de segmentation non supervisée	58
<b>2.3</b>	<b>Conclusion</b>	<b>66</b>

---

A ce jour, plusieurs systèmes de segmentation de l'iris qui exigent une qualité satisfaisante de l'image de l'iris ont été proposés. En effet, l'acquisition impose une forte coopération de l'individu. Ces systèmes efficaces ont montré leur performance dans des conditions contrôlées. L'objectif des nouvelles tendances est de relaxer ces conditions tout en préservant les performances. Or, dans ces conditions, la qualité des images se dégrade et de ce fait la segmentation de l'iris est plus difficile. La précision de la segmentation des images de l'iris joue un rôle crucial et influe directement sur les performances du système de reconnaissance de l'iris. Dans ce contexte, la communauté de recherche a porté une attention particulière à ce problème dans le but de proposer des systèmes de segmentation d'images de l'iris plus adéquats et plus efficaces.

Depuis 2008, deux grandes compétitions nommées NICE (Noisy Iris Challenge Evaluation) et MICHE (Mobile Iris Challenge Evaluation) ont été organisées pour encourager le développement de nouveaux systèmes de reconnaissance d'images dégradées de l'iris. La première session NICE-I a été consacrée au problème de segmentation des images de l'iris capturées en lumière visible par une caméra statique, tandis que, la compétition MICHE-I est destinée aux images de l'iris capturées en lumière visible par une caméra mobile (téléphones et tablettes). Les articles (130), (120), (94), (65), (68) acceptés et publiés dans ces deux compétitions ont proposé une segmentation des images en couleur. Par la suite, d'autres travaux (105), (128), (127), (129), (145), (78) ont proposé des méthodes adaptées à la segmentation de l'iris en couleur et en niveau de gris.

Nous consacrons ce chapitre à la présentation des principales approches de segmentation de l'iris qui suivent en général le schéma de fonctionnement présenté dans la figure 2.1. Notre classification des travaux existants est basée sur le type d'approches utilisées pour estimer les contours de l'iris. Nous considérons particulièrement deux grandes familles d'approches : les approches qui s'intéressent à la forme de l'œil (Tableau 2.1) et les approches qui portent sur les différentes régions de l'œil (Tableau 2.3). La première classe fait appel à des méthodes basées sur la recherche de contours et fonctionnent directement sur l'image en intensité de gris. La deuxième classe introduit des méthodes de recherche de régions en produisant un résultat intermédiaire qui sera utilisé ensuite pour l'approximation des contours.

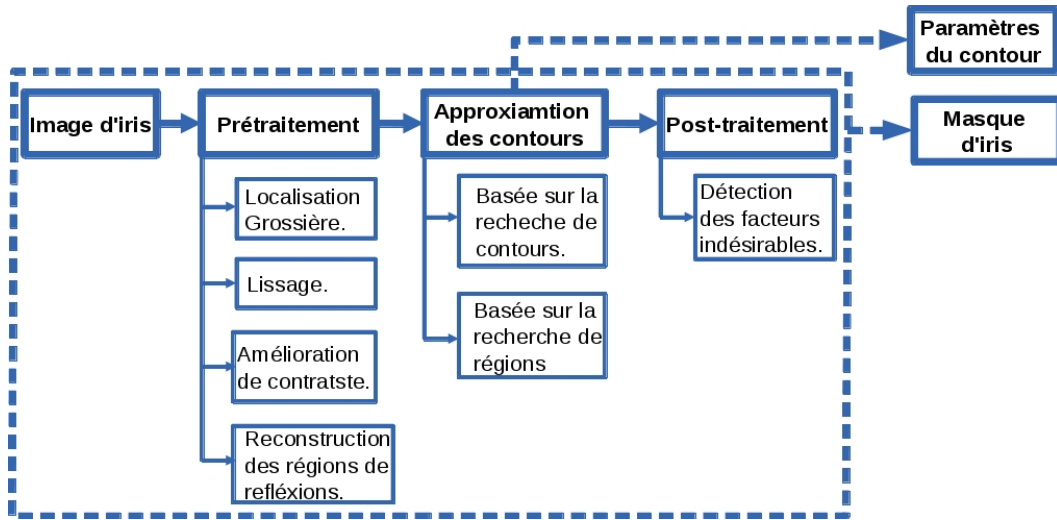


FIGURE 2.1 – Schéma général d'un système de segmentation de l'iris.

## 2.1 Approches basées sur la forme des contours de l'œil

Dans cette section, nous focalisons notre étude sur les méthodes basées sur la recherche de contours proposées pour la segmentation de l'iris. Nous regroupons les méthodes basées sur la recherche de contours en trois catégories : les méthodes basées sur l'opérateur intégrodifférentiel, celles basées sur la transformée de Hough et les autres méthodes.

### 2.1.1 Approches basées sur l'opérateur intégrodifférentiel

Le premier système de reconnaissance automatique et le plus employé dans les applications commerciales a été proposé par Daugman en 1993 (43). Il a proposé de modéliser les contours interne et externe de l'iris par deux cercles. Les paramètres des cercles sont estimés par l'opérateur intégrodifférentiel (IDO) donné par l'équation suivante :

$$\max_{(x_c, y_c, r)} \left| G_\sigma(r) * \frac{\delta}{\delta r} \oint_{(x_c, y_c, r)} \frac{I(x, y)}{2\pi\rho} ds \right| \quad (2.1)$$

Où  $(x_c, y_c, r)$  représentent les paramètres du cercle avec  $(x_c, y_c)$  comme coordonnées du centre et  $r$  son rayon,  $I(x, y)$  est l'intensité du pixel en position  $(x, y)$ .  $*$  représente l'opérateur de convolution,  $G_\sigma$  note le filtre gaussien avec l'écart type  $\sigma$ .



Cet opérateur fonctionne comme un détecteur de contours circulaires où la recherche se fait dans des endroits où la variation d'intensité est maximale. Dans le travail (43), une suppression empirique des parties supérieures et inférieures est effectuée. Par contre, Daugman améliore la détection des paupières dans son travail (45) et propose d'utiliser l'opérateur IDO qui est destiné à rechercher des courbes curvilignes pour la localisation des paupières. D'autres applications de l'opérateur IDO ont été décrites dans (30), (118), (121), (137), (146).

Malgré la robustesse de l'IDO lors de son application sur des images acquises dans des conditions contrôlées, il souffre du manque de stabilité dans des conditions non contrôlées. Cet opérateur est basé sur la variation maximale des intensités ce qui le rend trop sensible et très affecté par les maxima locaux créés par d'autres facteurs indésirables tels que les réflexions et les occlusions par les cils et/ou les paupières, etc.

L'approche décrite dans (120), classée en deuxième position dans la compétition NICE-I, consiste à segmenter l'iris en trois étapes : (i) détection des réflexions par un seuillage, (ii) recherche des contours de l'iris par l'IDO modifié et (iii) une modélisation paramétrique sous forme d'arcs circulaires des paupières. Contrairement à ce qui a été proposé par Daugman (43), les auteurs proposent d'augmenter l'angle de recherche des arcs circulaires vu que les occlusions par les paupières inférieures sont toujours moins fréquentes que celles produites par les paupières supérieures. En plus, les auteurs exploitent l'image en niveau de gris, produite par une transformation basée sur le modèle YIQ (luminance in-phase quadratique), ainsi que le canal rouge pour réaliser les trois étapes précédentes. Cette méthode fonctionne très bien lorsque les images sont acquises en laboratoire avec des réflexions plus ou moins importantes. En revanche, elle est sensible aux réflexions avec des formes complexes et une grande variation des intensités des pixels.

Haindl et Krupička (64) ont focalisé leur étude sur la recherche d'un bon masque de l'iris d'où la nécessité de bien détecter les différents facteurs indésirables (réflexions, cils, ombre, ...). Ils proposent d'utiliser l'IDO pour la recherche des contours de l'iris. Ensuite, ils classifient la texture de la région détectée en iris et non iris par l'utilisation d'un modèle probabiliste spatial multispectral. Cependant l'exploitation de l'information multispectrale est utilisée juste dans la détection des facteurs indésirables et pas dans la recherche des contours

de l'iris. Pour cette raison, les auteurs proposent dans le travail (65) une amélioration de la méthode (64). Cette nouvelle approche a enregistré les meilleures performances dans la compétition MICHE-I. Contrairement à la méthode (64) qui exploite directement l'image originale, la méthode proposée dans (65) travaille sur des images normalisées, générées par des cercles dans le but de construire un bon masque de l'iris. Une étape de pré-traitement permettant la détection des réflexions est adaptée afin de substituer la région des réflexions et produire une image reconstruite. Les auteurs généralisent l'IDO afin d'exploiter l'information multispectrale (Equation 2.2) et l'appliquent sur l'image reconstruite.

$$\max_{(\tilde{r}_1, \tilde{r}_2, \rho)} |G_\sigma(\rho) \otimes \frac{\delta}{\delta\rho} \oint_{(\tilde{r}_1, \tilde{r}_2, \rho)} \frac{Y_{r, \bullet}}{2\pi\rho} dsd\rho| \quad (2.2)$$

Où  $r = \{r_1, r_2\}$  et  $s = \{s_1, s_2\}$  représentent les multi-indices des lignes et colonnes,  $\bullet$  correspond aux indices spectraux,  $(\tilde{r}_1, \tilde{r}_2)$  représentent les coordonnées du centre du cercle et  $\rho$  est son rayon,  $Y_{r, \bullet}$  est le  $r^{ime}$  pixel multispectral,  $\otimes$  représente l'opérateur de convolution multispectrale,  $G_\sigma$  dénote le filtre gaussien 3D avec un écart type identique  $\sigma$  pour tous les canaux de couleur.

La recherche de cercles est réalisée dans les deux intervalles d'angles  $[0 - 45]$  et  $[135 - 360]$  pour éviter de prendre en compte les paupières supérieures qui détériorent la détection de l'iris. Par la suite, ils proposent d'utiliser l'image normalisée pour approximer les paupières par des courbes polynomiales et appliquer un modèle probabiliste spatial multispectral et un seuillage adaptatif pour distinguer entre la texture de l'iris et du non iris. Cette méthode a été destinée aux images en couleur prises par des caméras statiques ou mobiles.

### 2.1.2 Approches basées sur la transformée de Hough

Le deuxième système complet de reconnaissance de l'iris a été proposé dans (138) en 1997. Wildes s'est basé sur l'utilisation de la Transformée de Hough (HT) pour la segmentation de l'iris (93). Sa méthode est très basique. L'auteur détermine une carte de contours avec une simple détection de gradient et binarisation (comme Canny (138)). Puis, il applique la Transformé de Hough Circulaire (CHT) sur la carte des contours pour modéliser les frontières de l'iris par des cercles et la Transformé de Hough Linéaire (LHT) pour modéliser les

paupières. Le défaut de cette approche est que si la carte des contours ne présente pas les vrais contours de l'iris, la HT ne pourra pas détecter ces derniers. D'autres travaux basés sur la modification de détecteurs de contours ont été décrits dans (71), (79), (94). Ces méthodes sont assez stables mais dépendent grandement du détecteur de contours utilisé.

L'approche proposée par Chen et al (38) exploite la différence d'apparence entre la région de la sclera et les autres régions de l'image de l'œil afin de localiser la région de la sclera et de définir une région rectangulaire d'intérêt. Le fait de limiter les traitements sur la région ciblée rend ceux-ci plus faciles et plus rapides. Au lieu d'appliquer la CHT sur la carte des contours résultant de l'emploi du filtre de Sobel en quatre directions, les auteurs ont proposé de n'exploiter que les contours horizontaux produits par l'application du filtre de Sobel dans deux directions afin de diminuer le nombre de points de contours qui interviennent dans le traitement. Par ailleurs, toute mauvaise détection de la région de la sclera, à cause de la présence de régions plus brillantes que la sclera dans l'image de l'iris, conduit à une mauvaise segmentation de l'iris et par conséquent à une dégradation des performances.

Farihan et al. (57) visent à rendre la détection des cercles par la CHT plus précise en améliorant le contraste de l'image. Ils remarquent en effet que le faible contraste pupille/iris ou l'illumination faible de l'image constituent un vrai obstacle pour la réussite de la CHT. En plus, ils constatent que les différentes méthodes d'amélioration de contraste proposées dans la littérature pour la segmentation de l'iris n'exploitent que l'intensité en niveau de gris ou celle du canal rouge. Ils proposent alors d'améliorer le contraste de la couleur par l'utilisation de la méthode d'égalisation adaptative des histogrammes appelée iso-CLAHE (iso Contrast Limites Adaptative Histogram Equalization) sur des sous-régions de l'image. Cette méthode permet de manipuler localement la distribution de l'intensité de couleur.

Zhao et Kumar (145) exploitent le modèle de la variation totale relative (140) afin d'extraire la structure principale de l'image oculaire qui sera exploitée par la suite pour la détection des cercles par la HT modifiée. Ce modèle fonctionne comme un lissage de l'image tout en supprimant la texture et les différents détails dans l'image oculaire. Ils proposent d'utiliser une nouvelle variante de variation totale relative basée sur la norme  $L1$  au lieu de la norme  $L2$ . La partie la plus intéressante dans son travail consiste dans les post-traitements utilisés

pour supprimer les facteurs indésirables (réflexions, cils, ombre). Ces post-traitements sont basés sur une analyse locale des différentes régions présentées à l'intérieur du cercle trouvé par la HT. Cette analyse est fondée sur une approche de binarisation adaptative qui exploite l'histogramme de ces régions. En plus, deux régions rectangulaires dépendantes du centre et du rayon de l'iris sont définies pour rechercher les paupières supérieures et inférieures indépendamment et les estimer par un modèle parabolique. Enfin, l'approche proposée par les auteurs permet de classifier les différents pixels en iris et non iris. Malheureusement, cette méthode est sensible à la recherche des paupières puisque la région d'intérêt ne dépasse pas le rayon de l'iris. Il en résulte, une forte probabilité d'une mauvaise détection des paupières dans le cas où l'œil est bien ouvert c.à.d absence occlusion par les paupières (voir Figure 2.2).




FIGURE 2.2 – Détection des contours de l'iris et des paupières par la méthode (145). Bonne détection des cercles de l'iris (a), bonne détection des paupières supérieures (b), mauvaise détection des paupières inférieures (c).

### 2.1.3 Autres approches

En réalité, les contours de l'iris ne sont pas circulaires. Durant la dernière décennie, d'autres alternatives de segmentation de l'iris ont été présentées. Elles visent à étendre les contours circulaires à d'autres formes de contours. Nous citons le travail original présenté par Daugman (46) basé sur le contour actif et qui atteint de très bonnes performances dans des conditions contrôlées. Cependant, la forme du contour est altérée si on prend en compte des contours générés par des occlusions. Suivant le même principe, on peut citer l'utilisation des contours actifs géodésiques proposés par (116),(122), l'utilisation des modèle spatio-temporel ou une stratégie d'évolution des courbes (80), (132), (87). Une combinaison des contours actifs

géodésiques et une stratégie d'évolution des courbes a été proposée par (117). Néanmoins, ces méthodes sont fortement liées à la forme de l'iris, donc toute erreur de la détection de la forme de l'iris influence l'approximation des contours.

L'approche décrite dans le travail (125), et qui est implémentée dans le système de reconnaissance open source OSIRIS-V4 et sa version améliorée OSIRIS-V4.1 (92), vise à rechercher un contour précis de l'iris. Les auteurs proposent de rechercher un chemin optimal, qui unit un ensemble de points de gradients significatifs, par l'optimisation d'une fonction de coût. Afin d'atteindre ce but, ils ont utilisé l'algorithme de Viterbi en utilisant deux échantillonnages différents des points de gradient et ils ont ajouté une contrainte pour que la courbe soit fermée. L'application de l'algorithme de Viterbi en haute résolution (premier échantillonnage) permet la recherche d'un contour précis. Tandis que son application en basse résolution (deuxième échantillonnage) permet la recherche d'un contour grossier. Contrairement à la haute résolution où tous les pixels sont pris en compte, en basse résolution, un sous échantillonnage irrégulier est appliqué afin de prendre peu de points appartenant à la région des paupières et cils (Voir Figure 2.3). Dans ce travail, la méthode des moindres carrés est adoptée pour la recherche des cercles. Sachant que cette méthode est sensible aux valeurs aberrantes, elle est appliquée sur le contour grossier. Le masque de l'iris est construit à partir du contour précis qui sert à masquer la région des paupières et cils. Cependant, comme ce masque n'est pas suffisant, un seuillage adaptatif est mis en place pour supprimer tout autre type d'occlusion et reflets lumineux. Pour que ce processus puisse être exécuté, un centre initial de la pupille doit être estimé et des intervalles limitant les diamètres de la pupille et l'iris doivent être définis.




FIGURE 2.3 – Illustration de recherche de cercles sur différents contours (125). Contour de haute résolution (a). Cercle recherché sur un contour de haute résolution (b). Contour de basse résolution (c). Cercle recherché sur un contour de basse résolution (d).

L'inconvénient majeur de cette méthode est qu'elle est très sensible à l'estimation du centre initial de la pupille et d'autre part son utilisation est difficile dans un cadre de multirésolutions (images prises à différentes distances) puisque il est difficile de connaître à l'avance la variation du diamètre de l'iris et de la pupille. Pour cette raison, le travail dans (111) vise à l'améliorer en estimant le diamètre d'une manière automatique. Il explore l'information supplémentaire produite par la carte de gradients (en anglais Saliency map) qui est mesurée par une variation du contraste. Il utilise la méthode proposée dans (40) pour la construction de la carte de gradients suivie par un filtre anisotropique pour contrebalancer la variation de faible contraste afin de favoriser l'apparence de hautes variations autour du contour iris/sclera. Une corrélation entre l'image en question et un ensemble de prototypes d'images de l'iris de référence permet d'approximer le diamètre de l'iris. Cette méthode est souhaitable pour le

traitement des données en multirésolutions mais elle reste toujours sensible à l'estimation du centre initial de la pupille.

TABLE 2.1: Méthodes récentes de segmentation de l'iris basées sur la recherche de contours

Travail	Base de données	Pré-traitement	Approximation du contour de l'iris	Raffinement (paupières, cils, réflexions)
Daugman 1993 (43)	-	-	Opérateur intégrodifférentiel.	Élimination empirique .
Wildes 1997 (138)	-	-	Transformée de Hough circulaire.	transformée de Hough linéaire et seuillage.
Daugman 2007 (46)	UAE database <sup>+</sup> ,	-	Contour actif basé sur les séries de fourrier.	Méthodes d'inférence statistique.
Miyazawa et al 2008 (87)	CASIA-IrisV1.0 <sup>+</sup> , CASIA-IrisV2.0 <sup>+</sup> , ICE2005 <sup>+</sup>	Localisation de la pupille par seuillage	Stratégie d'évolution des courbes par l'utilisation d'un modèle déformable.	Détection des paupières sur l'image normalisée.
Shah et Ross 2009 (122)	CASIA-IrisV3.0 <sup>+</sup> , WVU Non-Ieal <sup>+</sup>	Localisation de la pupille par seuillage	Contour actif géodésique.	Méthodes des moindres carrés pour approximer des cercles.
Chen et al 2010 (38)	UBIRIS-v2 <sup>*</sup>	Détection des réflexions par seuillage adaptatif	L'opérateur intégrodifférentiel modifié.	Un arc circulaire modélise les paupières .

Satura et al. 2012 (125), Othman et al. 2015 (92)	ICE2005 <sup>+</sup> , CASIA- IrisV4- Thousand <sup>+</sup> .	Lissage anisotropique.	Algorithme de Viterbi et la méthode des moindres carrés pour la recherche des cercles .	Seuillage adaptatif.
Haindl et Krupička 2013 (64)	UBIRIS-v2* .	-	Opérateur intégrodifférentiel circulaire	Champ de Markov et seuillage adaptatif.
Haindl et Krupička 2015 (65)	UBIRIS-v2* .	Correction des réflexions par un algorithme de reconstruction, MICHE* .	Opérateur intégrodifférentiel généralisé.	Courbe polynomiale, champ de Markov et seuillage adaptatif.
Farihan et al. 2015 (57)	UBIRIS-v2* .	Suppression des réflexions (56), amélioration du contraste par iso-CLAHE.	Transformée de Hough circulaire.	transformée de Hough linéaire et seuillage.
Zhao et Kumar 2015 (145)	UBIRIS-v2*, FRGC*, CASIA- IrisV4- Distance <sup>+</sup> .	Modèle de variation totale.	Transformée de Hough circulaire modifiée.	Binarisation adaptative et modèle parabolique.
Raja et al. 2015 (111)	MICHE* , VSSIRIS*	Carte de gradient proposée par (40) pour estimer le diamètre de l'iris	Algorithme de Viterbi et la méthode des moindres carrés pour la recherche des cercles .	Seuillage adaptatif.
* : lumière visible + : lumière infra-rouge				



### 2.1.4 Limitations des approches basées sur la forme des contours de l'œil

Bien que les systèmes classiques de reconnaissance de l'iris fonctionnent très bien lors de l'acquisition contrôlée, la reconnaissance de l'iris doit être non contraignante et doit fonctionner dans des conditions d'acquisition non contrôlées afin de répondre aux différents besoins actuels.

En effet, les images dégradées de l'iris présentent en général différents artefacts qui correspondent à la variation d'illumination, le faible contraste, le flou, les différentes occlusions, etc. (Section 1.3.1.2). Ces facteurs indésirables rendent la segmentation de l'iris plus difficile avec des approches basées uniquement sur la recherche de contours. Dans ce cas, les contours ne correspondent pas bien aux contours réels et les images de l'iris normalisées résultant de l'application de la transformation de *rubbersheet* (Section 1.3.2.2), et qui sont utilisées par l'algorithme de correspondance lors de la comparaison des motifs, peuvent contenir des régions qui ne sont pas de l'iris et par conséquent l'appariement des motifs est voué à l'échec, même si les images proviennent du même œil.

Nous avons choisi de sélectionner les approches (65) (basée sur l'IDO généralisé), (145) (basée sur la HT modifiée), (125) (basée sur le Viterbi) comme des représentants de chaque catégorie des méthodes basées sur la recherche de contours parce qu'elles ont prouvé leurs bonnes performances de segmentation d'images dégradées de l'iris dans la littérature. Malgré les améliorations importantes proposées comme post-traitement par (65) et (145), il est intéressant de préciser que l'approximation des contours de l'iris n'est pas toujours efficace. La figure 2.4 illustre quelques exemples de mauvaises approximations des contours d'images dégradées de l'iris réalisées par (65), (145), (125).




FIGURE 2.4 – Exemples de mauvaises segmentations résultant de l'application des approches basées sur la recherche de contours. De haut en bas, les approches utilisées sont celles décrites dans : (125), (145),(65).

Développer des systèmes de segmentation de l'iris robustes et précis en utilisant ces images dégradées de l'iris est un défi important à surmonter. La proposition de nouvelles méthodes pour segmenter ces images de faible qualité est donc vivement souhaitable.

Dans ce travail, nous proposons d'explorer la potentialité et les caractéristiques offertes par les méthodes basées sur la recherche de régions. Ces méthodes ont été initialement proposées pour la segmentation des images des yeux en couleur et ont été adaptées par la suite à des images en niveaux de gris. En effet, les images en couleur sont beaucoup plus difficiles à segmenter que les images en niveaux de gris. Dans la section suivante, nous présenterons les méthodes récentes basées sur la recherche de régions comme un processus de pré-traitement avant l'approximation des contours de la région de l'iris.

## 2.2 Approches basées sur les différentes régions de l'œil

Contrairement aux méthodes de recherche de contours, la segmentation par des approches basées sur la recherche de régions revient à attribuer aux pixels un label spécifique à une région. Dans notre cas, l'intérêt est de segmenter l'iris, d'où la nécessité d'identifier les pixels appartenant à l'iris et d'appliquer par la suite une méthode de recherche de contours sur l'image labellisée pour modéliser les contours de l'iris.

Dans cette section, nous proposons une classification des méthodes récentes basées sur la recherche de régions en trois classes : (i) approches de segmentation supervisée, (ii) approches de segmentation semi-supervisée, (iii) approches de segmentation non supervisée. La première classe regroupe des méthodes qui utilisent l'apprentissage supervisé, d'où l'obligation de disposer d'une base d'apprentissage comprenant un ensemble d'images auxquelles une région a été attribuée souvent manuellement. Cette base est utilisée comme une vérité terrain afin d'apprendre le modèle de segmentation. La deuxième classe d'approches nécessite la connaissance à priori des informations caractéristiques des différentes régions recherchées. En revanche, la troisième classe d'approches n'exige aucune intervention a priori à part l'indication du nombre de régions à rechercher.

### 2.2.1 Approches de segmentation supervisée

Récemment, des approches basées sur l'utilisation des méthodes d'apprentissage ont été proposées afin de classifier les pixels iris. Proença (105) a introduit les réseaux de neurones pour catégoriser les pixels de l'iris et non iris. L'auteur propose de déterminer en premier lieu la région de la sclera en effectuant une classification binaire de l'image en sclera et non sclera. Au total il faut un ensemble de 20 caractéristiques (Équation 2.3) pour apprendre la classe sclera.

$$\{x, y, hue_{0,3,7}^{\mu,\sigma}(x, y), cb_{0,3,7}^{\mu,\sigma}(x, y), cr_{0,3,7}^{\mu,\sigma}(x, y)\} \quad (2.3)$$

Où  $(x,y)$  représente la position du pixel,  $hue()$ ,  $cb()$ ,  $cr()$  décrivent respectivement une région locale centrée en position  $(x,y)$  des trois canaux : teinte, chroma bleu, chroma rouge. Pour chaque canal, trois régions de rayon égal à  $\{0, 3, 7\}$  sont extraites. La moyenne  $\mu$  et l'écart

type  $\sigma$  représentent les statistiques d'ordre un et deux liées à chaque région.

Ensuite, l'auteur se sert des données obtenues dans l'étape de la détection de scléra pour construire de nouvelles caractéristiques. Ces dernières sont représentées par les différentes proportions de la sclera (Voir Figure 2.5) qui sont mesurées dans différentes directions (Ouest, Est, Nord, Sud) par rapport à la position  $(x,y)$  suivant l'équation suivante :

$$\begin{aligned}
 p_{\leftarrow}(x, y) &= \mu(sc((1, y - 1), (x, y))) \\
 p_{\rightarrow}(x, y) &= \mu(sc((x, y - 1), (w, y))) \\
 p_{\uparrow}(x, y) &= \mu(sc((x - 1, 1), (x, y))) \\
 p_{\downarrow}(x, y) &= \mu(sc((x - 1, y), (x, h)))
 \end{aligned}
 \tag{2.4}$$

Où  $sc((\dots),(\dots))$  représente la région extraite de l'image résultant de l'étape de détection de la sclera (Figure 2.5). Cette région est délimitée par les coordonnées du coin gauche haut et du coin droit bas.  $w, h$  expriment la taille de l'image.  $p()$  est égal à zero pour tous les pixels de la sclera.




FIGURE 2.5 – Proportions de sclera obtenues à partir des images de l'iris frontale (première ligne) et off-angle (deuxième ligne) (105). Détection de la sclera (a et d). Proportion de sclera dans la direction est (b et e). Proportion de sclera dans la direction ouest (c et f).

Ces proportions de sclera sont combinées avec d'autres caractéristiques de l'image pour

la construction d'un vecteur de caractéristiques de taille 18 (Équation 2.5).

$$\{x, y, S_{0,3,7}^{\mu,\sigma}(x, y), p_{\leftarrow, \rightarrow, \uparrow, \downarrow}(x, y)\} \quad (2.5)$$

Où  $S()$  dénote la région locale de la composante couleur « saturation ».  $p_{\leftarrow, \rightarrow, \uparrow, \downarrow}(x, y)$  représentent les différentes proportions de la sclera.

Ce vecteur de caractéristiques est utilisé pour apprendre l'iris (Figure 2.6). Enfin, l'auteur propose d'estimer les contours de la région de l'iris par une courbe polynomiale de degré 10.




FIGURE 2.6 – Exemples de classification en iris et non iris par apprentissage supervisé (105).

Cependant, les différentes caractéristiques définies pour apprendre la région de la sclera peuvent être non stables et non discriminantes. Malheureusement, les composantes de teinte et de chroma bleu et rouge ne maximisent pas toujours le contraste iris/sclera. La figure 2.7 montre que plus la distance d'acquisition est grande, moins l'information contenue dans ces trois composantes est fiable, ce qui affecte directement la détection de la région de la sclera. Or, une mauvaise détection de la région de la sclera induit une dégradation significative des performances de segmentation. En effet, l'auteur propose d'approximer les contours sur le masque résultant de la segmentation, donc une mauvaise classification des pixels de l'iris peut altérer l'étape d'approximation des contours et par conséquent une dégradation des performances de reconnaissance.




FIGURE 2.7 – Extraction des caractéristiques de la sclera de différentes images prises à différentes distances. De haut en bas : image originale, composante teinte, composante chroma blue, composante chroma rouge. De gauche à droite : distance d’acquisition en mètres (4,5,6,7,8).

Suivant la même voie, Tan et al (128) emploient les deux modèles les plus répandus en apprentissage supervisé : le réseau de neurones et la machine à vecteurs de support. Ils se basent sur les moments locaux de Zernike pour classifier les pixels en iris et non iris, sans aucune nécessité de détecter la région de la sclera. Le résultat de la classification attendu est proche de celui montré dans la Figure 2.6. Les auteurs proposent d’extraire six caractéristiques pour chaque pixel (voir Équation 2.6).

$$\{x, y, I(x, y), Z_{mn}^l(I, x, y)\} \quad (2.6)$$

Où  $x, y$  sont les coordonnées du pixel,  $I(x, y)$  la valeur de l’intensité de l’image pré-traitée par l’algorithme Single Scale Retinex (25) pour améliorer le contraste. Les auteurs précisent qu’ils utilisent le canal rouge si l’image est en couleur.  $Z_{mn}^l(I, x, y)$  note le moment local de Zernike d’ordre  $m$  et de répétition  $n$ . Le calcul des moments de Zernike se fait sur des régions locales de rayons différents  $l = \{2, 5, 7\}$ . L’ordre de Zernike  $m$  est égal à 4 et 6 respectivement pour

les images en couleur et en niveaux de gris, le nombre de répétition de Zernike est égal à 0.

Pour corriger les fausses classifications introduites par les classifieurs proposés, les auteurs proposent un ensemble de post-traitements pour estimer le centre de l'iris, raffiner les contours, masquer la pupille, détecter les paupières et supprimer les réflexions et les cils.

Une nouvelle méthode qui vient d'être publiée dans (78) utilise les réseaux de neurones profonds. Les auteurs proposent de comparer les modèles HCNNs (Hierarchical Convolutional Neural Networks), MFCNs (Multi-scale Fully Convolutional Network) avec les différentes récentes méthodes de l'état de l'art. Ils ont montré que le modèle MFCNs surpasse le modèle HCNNs et même tous les modèles proposés dans (105), (128), (130), (129), (145). À l'opposé de tous ces travaux, le MFCNs n'exige aucun pré-traitement ou post-traitement. Il est robuste aux différentes variations d'illumination.

Afin d'assurer l'apprentissage supervisé exigé par ces méthodes, une segmentation manuelle pour chaque image oculaire de la base d'apprentissage doit être effectuée pour produire une vérité terrain du masque de l'iris. Il faut noter que la seule vérité terrain commune et publique est celle correspondante aux sous-bases UBIRIS-v2 utilisées dans les deux compétitions NICE-I et NICE-II. Il faut préciser que d'autres bases ont été évaluées dans les travaux (105), (128), (78). L'annotation de ces bases (CASIA-IrisV4-distance, FRGC et ICE) a été réalisée manuellement par les auteurs à cause de l'absence de vérité terrain commune et publique. Dans chaque travail, une sélection d'images et de sujets a été faite pour construire les ensembles d'apprentissage et de test. Cependant, aucune comparaison absolue ne peut être effectuée entre ces trois travaux parce que les sous-ensembles testés sont différents (Tableau 2.2).

En plus, ces méthodes fonctionnent au niveau pixel ce qui rend les temps de calcul très lents. Autrement dit, ces méthodes ne peuvent pas être déployées dans des applications réelles sans optimisation architecturale ou algorithmique.

TABLE 2.2: Nombre d'images et nombre de sujets employés dans les ensembles d'apprentissage et de test par différentes bases et différents travaux dans la littérature.

		<b>ICE2005</b>	<b>CASIA-IrisV4-Distance</b>	<b>UBIRIS-v2</b>	<b>FRGC</b>
(105)	Apprentissage	30 images	-	30 images	30 images
	Test	500 images	-	500 images	500 images
(128)	Apprentissage	-	41 images (6 sujets)	40 images (17 sujets) (NICE-II)	40 images (13 sujets)
	Test	-	502 images (67 sujets)	904 images (152 sujets) (NICE-II)	500 images (150 sujets)
(78)	Apprentissage	-	300 images (30 premiers sujets)	500 images (NICE-I)	-
	Test	-	100 images (10 sujets)	445 images (NICE-I)	-

### 2.2.2 Approches de segmentation semi-supervisée

Dans cette section, nous décrivons les récentes méthodes de segmentation semi-supervisée proposées pour la segmentation des images dégradées de l'iris. Ce type de méthodes implique une connaissance *a priori* des caractéristiques des différentes régions de l'image.

L'approche proposée dans (130) consiste à optimiser la version originale de l'opérateur IDO. Cette nouvelle version d'IDO est désignée comme la meilleure méthode soumise à la compétition NICE-I. Une suppression des réflexions par la méthode (66) est appliquée. Ensuite, les auteurs utilisent un modèle basé sur la connexion des 8-voisins (Figure 2.8) pour



regrouper l'image oculaire en régions. Ils se servent des différentes caractéristiques de régions pour initialiser le regroupement. Ils considèrent, comme une connaissance *a priori*, le fait que l'intensité de la région de l'iris est plus sombre que celle de la peau. Le choix de la région de l'iris candidate se fait à l'aide d'autres règles sémantiques qui sont basées sur des connaissances *a priori*. Ensuite, une recherche des contours de l'iris est réalisée à l'aide d'une version accélérée de l'opérateur IDO qu'ils ont proposée. Cette amélioration consiste à évaluer un ensemble de points candidats qui sont définis dans un modèle de constellation (Figure 2.9) au lieu de faire une recherche exhaustive. Ce choix intelligent des points à traiter permet une accélération des temps de calcul. Enfin, le post-traitement effectué pour localiser et détecter les paupières, les cils et l'ombre est inspiré du travail décrit dans (66).




FIGURE 2.8 – Exemple du regroupement en régions proposé par (130). Regroupement basé sur la connexion des 8-voisins (a). Labellisation sémantique (b).

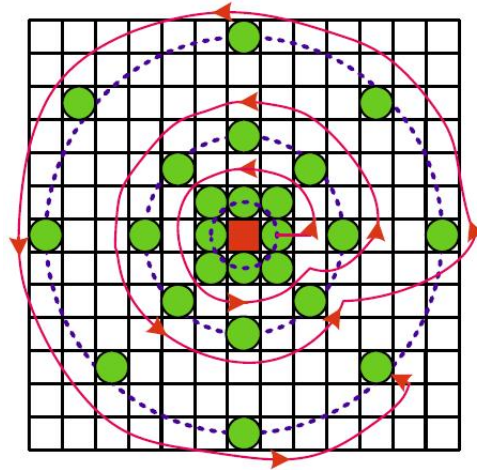


FIGURE 2.9 – Version améliorée de l’opérateur IDO basée sur un modèle de constellation (130). Les points candidats sont en vert et la trajectoire de recherche en rouge. Les anneaux de rayons 1, 3, 6 sont pointillés.

Cette méthode présente des défauts. Le module de regroupement est sensible aux fortes variations d’illumination et il regroupe l’iris brillant dans la région de la peau ce qui induit par la suite une mauvaise localisation de l’iris. Par ailleurs, même si les pixels sont bien regroupés, les règles sémantiques définies pour le choix de la région de l’iris ne sont pas efficaces pour une bonne détermination de cette région dans le cas des images fortement dégradées. Notons que le choix des points candidats pour appliquer l’opérateur IDO peut s’avérer peu performant.

Contrairement à leur premier travail (128) fondé sur des méthodes d’apprentissage supervisé, Tan et Kumar (127) développent une méthode de segmentation basée sur l’emploi d’un modèle simple pour estimer la région de l’iris en classifiant les pixels d’image en iris et non iris. Les auteurs exploitent les automates cellulaires en particulier l’algorithme Grow-cut (133) pour réaliser la segmentation de la région de l’iris. L’avantage de cet algorithme est qu’il est rapide par rapport aux modèles basés sur l’apprentissage et n’exigent aucune vérité terrain. En revanche, cet algorithme nécessite une étape d’initialisation des classes recherchées par une intervention de l’utilisateur. En effet, les auteurs proposent de se baser sur des connaissances *a priori* de l’image originale pour initialiser le modèle d’une manière automatique. Pour cette raison, une formule basée sur le mode et l’écart type de l’image originale

est utilisée pour exprimer le fait que la région la plus sombre représente la pupille et l'iris, et la région la plus claire est composée par la sclera et les paupières. Il faut préciser que l'association des cils à une des classes précédentes dépend de leur couleur. Puis, ils appliquent le même post-traitement proposé dans (128) pour extraire les régions indésirables et produire le masque de l'iris.

En se basant sur la notion de modèles simples et rapides, une autre méthode proposée par Tan et Kumar (129) est basée sur l'utilisation de l'algorithme de marche aléatoire (en anglais Random Walker) (63) pour réaliser une classification grossière de l'image de l'œil en iris et non iris (Figure 2.10). Ils proposent la méthode d'initialisation reportée dans (127) pour initialiser le modèle. Il est bien connu que ce genre de modèle est rapide mais ne produit pas une classification fine comme les modèles basés sur l'apprentissage ou le modèle Grow-cut. Pour cette raison, les auteurs proposent une séquence de différentes opérations comme post-traitement pour raffiner la région de l'iris. Ce post-traitement consiste à : (i) estimer le centre de l'iris en employant l'image de l'iris classifiée par l'algorithme de marche aléatoire, (ii) localiser la pupille et l'iris et les modéliser avec un modèle circulaire, (iii) raffiner les contours par exploitation de l'information statistique des intensités des pixels, (iv) localiser les paupières avec un modèle adaptatif basé sur des courbes polynomiales et (v) supprimer les cils et les ombres par un seuillage adaptatif.



FIGURE 2.10 – Exemples de classification grossière en iris et non iris par l'algorithme de marche aléatoire (129).

La méthode de segmentation en régions décrite dans (59), (5), (60) et basée sur l'algo-

l'algo- rithme de ligne de partage des eaux (115) (en anglais Watershed) ne peut être utilisée que pour la segmentation en régions des images en couleur (Figure 2.11), car elle exploite explicitement les trois composantes de la couleur (R,G,B). La version initiale (59) consiste à produire une segmentation en petites régions par cet algorithme. Puis, une étape de fusion des petites régions est appliquée pour faire face au problème de sur-segmentation engendré par l'algorithme de ligne de partage des eaux. Ensuite, une image binarisée (notée BW) est construite pour produire une classification grossière de l'iris. Enfin, l'algorithme de Taubin (131) est appliqué sur l'image binarisée pour approximer les contours de l'iris par des cercles.

Les auteurs de (5) ont proposé une amélioration de la version décrite dans (59). Ils exploitent la région identifiée par les cercles comme une région d'intérêt. Cette dernière subit une séquence de post-traitements dans le but d'éliminer tous les facteurs indésirables pour construire un masque de l'iris plus fin. Ce post-traitement raffine en premier les contours de l'iris par l'analyse de la transformée de ligne de partage des eaux aux contours de la zone d'intérêt. Ensuite, un cercle est choisi selon les mesures d'homogénéité et de séparabilité parmi un ensemble de cercles candidats pour approximer les contours de la pupille.

Cependant, les auteurs de (60) ont adapté la méthode (5) pour qu'elle fonctionne sur des images prises par des caméras statiques. Ils ont révisé l'ensemble du jeu de paramètres ainsi que l'étape de la recherche de la pupille. Ils ont proposé une nouvelle définition de la mesure de séparabilité. Cette dernière est similaire à l'IDO.




FIGURE 2.11 – Illustration de la segmentation par la méthode (59). Transformée de partage des eaux (a). Image en couleur correspondante à la transformée de partage des eaux(b). Classification grossière de l'iris par binarisation (c).

### 2.2.3 Approches de segmentation non supervisée

Le premier travail qui a proposé d'utiliser des méthodes non supervisées pour la segmentation de l'iris a été réalisé par Proença et Alexandre (103) en 2006. Les auteurs comparent quatre méthodes de regroupement non supervisées : Kmeans, Kmeans flou (en anglais fuzzy Kmeans), cartes topologiques, espérance-maximisation (en anglais Expectation-Maximisation). L'évaluation de ces méthodes a montré que l'utilisation du Kmeans flou produit une image intermédiaire (Figure 2.12) qui favorise la recherche des contours précis par la HT. Il faut préciser que chaque pixel a été caractérisé par trois composantes : les coordonnées de la position du pixel et l'intensité en niveau de gris. En plus, ils ont appliqué un détecteur de contours (Canny) avant la HT. Ils ont montré que cette méthode est capable d'analyser des images dégradées bien mieux que ne le font d'autres approches (43), (30), (119), (138).




FIGURE 2.12 – Exemple d'une image segmentée par l'algorithme Kmeans flou (103).

Dans la méthode reportée dans (94) classée en quatrième position à NICE.I, les auteurs ont proposé de localiser les contours de l'iris par une exploitation du regroupement Kmeans suivie par une HT modifiée. Les auteurs utilisent un classifieur basé sur l'algorithme Ada-Boost (135) afin de localiser grossièrement la région de l'œil comme une première étape. La deuxième étape consiste à appliquer l'algorithme Kmeans mesurant le coefficient de Bhattacharya comme distance pour réaliser le regroupement des pixels en régions (Figure 2.13). Chaque pixel est caractérisé par un histogramme de cooccurrence. Les régions recherchées

sont : l'iris, la peau, la sclera, la pupille. La troisième étape vise à localiser une région d'intérêt par l'application de la TH elliptique sur la carte de contours. La quatrième étape repose sur une sélection d'un meilleur cercle parmi les dix premiers trouvés par la CHT. Le cercle avec le score intégrodifférentiel le plus élevé est choisi. L'IDO circulaire est appliqué sur une région rectangulaire extraite de l'image originale dépendant du rayon de l'iris pour localiser le contour pupille/iris. Enfin, un post-traitement est réalisé pour la détection des paupières et la suppression des réflexions.



FIGURE 2.13 – Exemple d'une image segmentée en classes par l'algorithme Kmeans basé sur l'histogramme de cooccurrence (94).

Selon les auteurs de cet article, plusieurs facteurs peuvent être à l'origine de la mauvaise segmentation de l'iris. Ils ont mentionné qu'il est probable que le détecteur AdaBoost, la détection de la pupille, la détection des paupières et la suppression des réflexions puissent être erronés. On peut conclure que la seule étape qui peut être considérée plus ou moins stable est celle de la recherche du contour iris/sclera basée sur le regroupement en régions. La Figure 2.14 illustre quelques exemples de mauvaises segmentations.




FIGURE 2.14 – Quelques exemples d’images mal segmentées de l’iris (94). Mauvaise approximation du contour pupille/iris (a). Mauvaise détection des paupières supérieures (b). Problème de segmentation dû à la mauvaise localisation de l’œil par AdaBoost (c).

Parmi les huit articles publiés suite à la compétition MICHE-I, trois d’entre eux s’intéressent particulièrement au problème de segmentation de l’iris capturés par des caméras mobiles. Les auteurs de (68) ont introduit la segmentation des images de l’iris en régions par l’algorithme SLIC (Simple Linear Iterative Clustering) (6). Cet algorithme est une adaptation de l’algorithme Kmeans avec une prise en compte de la notion spatiale, locale et de couleur pour générer des régions homogènes appelées super-pixels (Figure 2.15). Il préserve la structure locale de l’image. Ensuite, l’entropie basée sur l’histogramme de corrélation est utilisée pour caractériser les pixels de l’iris et produire une carte grossière de l’iris (Figure 2.15). Cette dernière est utilisée pour estimer un ensemble de candidats de centre de l’iris. Pour chaque candidat, les points avec un maximum local de la dérivée directionnelle sont utilisés pour approximer une régression circulaire ou elliptique de norme L1. Le contour avec le score de Daugman (43) le plus élevé est sélectionné. Enfin, les auteurs se sont inspirés du travail (94) pour approximer les paupières.




FIGURE 2.15 – Illustration du regroupement par l’algorithme SLIC (68). Super-pixels sur l’image (a). Carte grossière de l’iris (b).

Notre étude de l’état de l’art a montré qu’il existait des méthodes non supervisées de segmentation de l’iris. À notre connaissance, très peu d’auteurs ont examiné des méthodes basées sur des **modélisations statistiques** pour réaliser une segmentation non supervisée de l’iris. Ces méthodes ont montré leur efficacité dans de nombreux domaines. Ces modèles statistiques reposent sur une optimisation d’une fonction d’énergie permettant de détecter des régions homogènes. Le premier effort pour introduire des modélisations statistiques a été présenté par (107) afin de réaliser une segmentation non supervisée de l’image oculaire en régions (Figure 2.16). Il faut préciser que les régions recherchées sont la pupille, l’iris, les cils et le fond (le reste de l’image). Cette méthode est basée sur une combinaison de l’apparence du pixel (niveau de gris) et l’information topologique de l’image oculaire. Elle consiste à modéliser l’image par un Champ de Markov Caché (en anglais Hidden Markov Field (HMF)) avec la technique de coupure de graphe pour minimiser l’énergie. Le modèle fonctionne en



deux niveaux : une segmentation grossière après apprentissage qui est ensuite utilisée pour initialiser le TMF. Enfin, les auteurs proposent d'appliquer l'algorithme RANSAC sur l'image segmentée produite par le modèle HMF afin de modéliser les contours de l'iris sous forme d'ellipse. Lors de la comparaison avec des méthodes classiques, cette méthode atteint de bonnes performances en terme de détection de contours paramétrés.

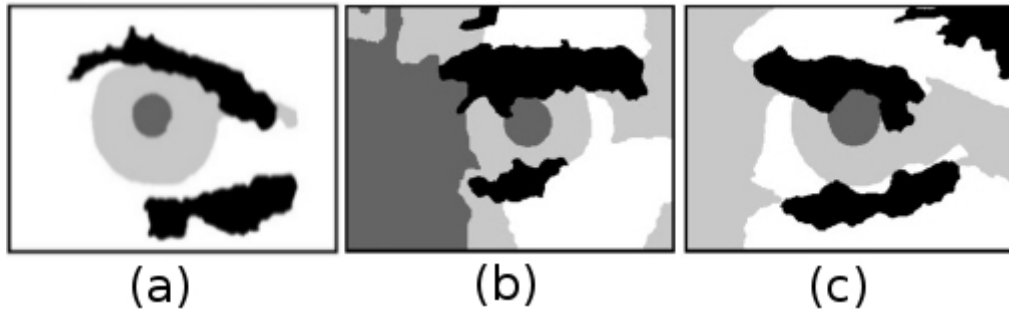


FIGURE 2.16 – Exemples de segmentation par Champs de Markov Cachés et minimisation d'énergie par des coupures de graphe (107). Bonne segmentation (a). Fusion de la région de la pupille avec d'autres pixels du fond (b). Fusion de la région de l'iris avec d'autres pixels du fond (c).

Il est à mentionner que la méthode décrites dans (107) présente quelques défaillances (Figure 2.16). Cette approche est basée sur l'analyse de la texture et de la distribution des niveaux de gris pour initialiser les différentes régions. Cependant, la pauvreté de la texture autour des cils conduit à des erreurs d'initialisation de la région des cils. En effet, le faible contraste iris/sclera provoque une fusion de la région de l'iris avec d'autres pixels du fond. En plus, il se peut que la pupille soit fusionnée avec d'autres pixels du fond ayant des valeurs de niveaux de gris proches.

Récemment, un nouveau travail basé sur les Champs de Markov Triplets (en anglais triplet Markov Field (TMF)) a été mis en œuvre par (13) pour effectuer une segmentation non supervisée de l'image de l'iris (Figure 2.16). Les TMFs représentent une extension des modèles HMFs classiques. Dans cette approche, les auteurs se sont intéressés à détecter les mêmes régions que celles recherchées dans le travail (107) (la pupille, l'iris, les cils et

le fond) . Ils ont proposé d'utiliser l'algorithme Kmeans pour initialiser ces régions sans besoin d'une initialisation suite à une méthode d'apprentissage. L'utilisation des TMFs a montré son efficacité par rapport aux HMFs pour la segmentation des images dégradées de l'iris. Cependant, l'algorithme Kmeans a des limites : il est difficile de regrouper les cils avec l'algorithme Kmeans en une région à part puisque les niveaux de gris de cette région sont très proches de ceux de la pupille ou de ceux de l'iris. En plus, il est clairement connu que l'algorithme Kmeans est sensible aux faibles contrastes ce qui peut induire une fusion complète ou partielle de différentes régions. Par conséquent, l'initialisation par Kmeans peut induire une mauvaise initialisation des régions recherchées, ce qui peut engendrer de mauvaises segmentations de l'iris par la suite.

En général, les méthodes basées sur les champs de Markov (HMF ou TMF) sont sensibles aux problèmes d'illumination et très coûteuses en temps de calcul. Par conséquent, il est difficile d'intégrer ce genre de méthodes dans des applications réelles.




FIGURE 2.17 – Exemples de segmentation par les Champs de Markov Triplets (13). Bonne segmentation (a). Fusion partielle entre le fond et l'iris (b,c).

TABLE 2.3: Méthodes récentes de segmentation de l'iris basées sur la recherche de régions

Travail	Base de données	Recherche régions	Approximation du contour de l'iris	Raffinement (paupières, cils, réflexions)
Li et al. 2010 (94)	UBIRIS-v2*	K-means basé sur l'histogramme de cooccurrence.	Transformé de Hough circulaire pour approximer le contour iris/sclera et l'opérateur intégrodifférentiel circulaire pour approximer le contour pupille/iris.	Opérateur intégrodifférentiel parabolique combiné avec l'algorithme RANSAK.
Tan et al. 2010 (130)	UBIRIS-v2*	Suppression des réflexions (66), regroupement des pixels de l'iris selon les 8-voisins.	Modèle de constellation intégrodifférentiel.	Modèle parabolique et Modèles prédictifs des cils.
Pundlik et al. 2010 (107)	WVU Non-Ieal <sup>+</sup> , WVU Off-Axis <sup>+</sup> .	Champs de Markov cachés et minimisation d'énergie avec la coupe du graphe.	Algorithme RANSAK pour estimer des ellipses.	-

Proença 2010 (105)	UBIRIS-v2*, FRGC*, ICE2006 <sup>+</sup> .	Réseaux de neurones (position de la région de scléra et les descripteurs couleurs) .	Courbe polynomiale de degré 10.	-
Tan et Kumar 2012 (128)	UBIRIS-v2*, FRGC*, CASIA-v4 distance <sup>+</sup> .	Algorithme Grow-cut.	modèle circulaire.	Courbe polynomiale et seuillage adaptatif .
Tan et Kumar 2012 (128)	UBIRIS-v2*, FRGC*, FRET*, CASIA-v4 distance <sup>+</sup> .	Réseaux de neurones et machine à vecteur de support (moments locaux de Zernike).	Modèle circulaire .	Courbe polynomiale et seuillage adaptatif.
Tan et Kumar 2013 (129)	UBIRIS-v2*, FRGC*, CASIA-v4 distance <sup>+</sup> .	Algorithme de marche aléatoire.	modèle circulaire.	Courbe polynomiale et seuillage adaptatif .
Frucci et al. 2013 (59), Abate et al. 2015 (5) , Frucci et al. 2016 (60)	UBIRIS-v1*, UBIRIS-v2*, MICHE*.	Segmentation par ligne de partage des eaux.	Modèle circulaire	Analyse de l'information résultante de la segmentation en régions et les cercles .
Benboudjema et al. 2013 (13)	ICE2005 <sup>+</sup> .	Champs de Markov Triplets.	Algorithme de Viterbi et la méthode des moindres carrés pour la recherche des cercles .	Seuillage adaptatif.

Yang et al. 2015 (68)	UBIRIS-v1*, UBIRIS-v2*, FRGC*, MICHE*	Regroupement en super-pixel par l'algorithme SLIC, binarisation OTSU.	Régression circulaire et elliptique de norme L1.	Modèle hyperbolique et seuillage.
Liu et al 2016 (78)	UBIRIS-v2*, CASIA-v4 distance <sup>+</sup> .	Réseaux de neurones profonds.	-	-
* : lumière visible + : lumière infra-rouge				

## 2.3 Conclusion

Dans ce chapitre, nous avons présenté une étude des différentes approches récentes de segmentation d'iris de la littérature. Nous avons identifié deux grandes familles d'approches pour la segmentation de l'iris : approches basées sur la forme de contours de l'œil ou sur les différentes régions de l'œil. Nous nous intéressons dans cette étude aux approches basées sur la recherche de régions, précisément aux méthodes basées sur des modélisations statistiques pour différentes raisons. Premièrement, peu de modélisations statistiques ont été explorées pour la segmentation non supervisée des images oculaires difficiles, que nous considérons comme une principale raison. Deuxièmement, l'échec des méthodes basées sur la recherche de contours de segmenter des images oculaire difficiles. Troisièmement, les méthodes basées sur la recherche de régions ont été proposées soit pour faciliter la localisation grossière de l'iris, soit pour approximer uniquement le contour iris/sclera. Ces méthodes explorent par la suite l'image originale pour approximer le contour pupille/iris.

Le but général des chapitres suivants est de présenter les modélisations statistiques basées sur les chaînes de Markov en explorant le problème de segmentation non supervisée des images d'iris difficiles, qui fait l'objet principal de ce travail de recherche.

## Chapitre 3

# Modèles statistiques pour la segmentation

---

<b>3.1 Généralités sur la segmentation bayésienne</b> . . . . .	<b>69</b>
3.1.1 Estimateurs Bayésiens . . . . .	70
3.1.2 Méthodes d'estimation des paramètres . . . . .	71
<b>3.2 Chaînes Markov Cachées</b> . . . . .	<b>76</b>
3.2.1 Définition du modèle . . . . .	76
3.2.2 Estimation des paramètres d'une HMC . . . . .	77
3.2.3 Restauration d'une HMC . . . . .	78
<b>3.3 Chaînes Markov Couples</b> . . . . .	<b>80</b>
3.3.1 Définition du modèle . . . . .	80
3.3.2 Estimation des paramètres d'une PMC . . . . .	81
3.3.3 Restauration d'une PMC . . . . .	83
<b>3.4 Chaînes Markov Triplets</b> . . . . .	<b>83</b>
3.4.1 Définition du modèle . . . . .	84
3.4.2 Estimation des paramètres . . . . .	85
3.4.3 Restauration des chaînes de Markov triplets . . . . .	87
<b>3.5 Conclusion</b> . . . . .	<b>88</b>

---

La segmentation statistique des images basée sur des modélisations markoviennes a vu le jour suite à l'introduction des HMF (62), (16), (82). Ce genre d'approches a prouvé son efficacité dans différentes applications, en particulier en imagerie satellitaire (58), (136), (143), en imagerie médicale (144), (8), (9), en imagerie sonar (85), (86), (124), dans quelques applications par vision d'ordinateur (61), (29), (77), et en biométrie (107), (13). Selon l'application visée, le résultat de la segmentation peut être observé directement comme un résultat final du problème traité. Dans d'autres cas, ce résultat est considéré comme une solution intermédiaire qui sera exploitée, par la suite, par un ensemble de post-traitements afin de fournir le résultat final. Dans ce travail de recherche, nous avons considéré la segmentation des images dégradées de l'iris comme une solution intermédiaire qui sera suivie par une approximation des frontières afin de modéliser les contours et de construire le masque de l'iris.

Dans ce cadre de travail, la segmentation d'une image se ramène à l'estimation bayésienne d'un processus aléatoire caché, considéré toujours à valeurs discrètes, à partir d'un processus observé. On modélise le lien entre les deux processus à travers une loi de probabilité. La loi jointe permet de modéliser toutes les dépendances possibles entre les pixels de l'image. De ce fait, un bon choix de la loi jointe est primordial. Dans le cas général, plus la structure de dépendance est complexe, plus la loi jointe est riche. Cette richesse rend l'estimation du processus caché difficile voire impossible, surtout quand la taille des images est très importante. L'utilisation des modèles Markoviens (chaînes, champs, arbres) permet de contourner ce problème en introduisant un modèle de dépendance entre les pixels. En particulier, les chaînes de Markov se sont souvent montrées efficaces dans plusieurs domaines. D'une part, elles assurent un calcul explicite des probabilités *a posteriori* en temps raisonnable contrairement aux modèles basés sur les champs de Markov qui font appel à des méthodes de simulations itératives (échantillonneur de Gibbs, recuit simulé) qui sont coûteuses en temps de calcul. D'autre part, elles permettent une estimation automatique des paramètres du modèle. Pour cette raison, nous nous sommes intéressés à étudier exclusivement, dans ce travail, des modélisations statistiques basées sur des chaînes de Markov afin de réaliser une segmentation non supervisée des images dégradées de l'iris.

Ce chapitre est consacré aux fondements de la segmentation bayésienne. Nous introduisons les estimateurs bayésiens permettant la restauration du processus caché. Puis, nous présentons quelques méthodes automatiques d'estimation des paramètres de sorte que la segmentation puisse se faire d'une manière non supervisée. Ensuite, nous décrivons des modèles de généralité croissante basés sur les chaînes de Markov. Pour chaque modèle, une présentation de l'estimation des paramètres et la restauration du processus caché est détaillée.

### 3.1 Généralités sur la segmentation bayésienne

Dans le cadre de la segmentation d'images, il est naturel de faire appel à des approches bayésiennes lorsqu'il s'agit de déterminer des caractéristiques cachées à partir des observations. Il est fréquent de considérer une image avec un nombre total de pixel  $N = l \times c$  (avec  $l$  nombre de lignes et  $c$  nombre de colonnes) comme un processus aléatoire observé et l'image de classes correspondantes comme un processus aléatoire caché. Nous définissons deux processus aléatoires, le processus observé  $Y = (Y_1, Y_2, \dots, Y_N)$  qui prend ses valeurs dans  $\mathbb{N}$  et le processus caché  $X = (X_1, X_2, \dots, X_N)$  qui prend ses valeurs dans un ensemble fini  $\Omega = \{\omega_1, \omega_2, \dots, \omega_K\}$ . La loi jointe de  $Z = (X, Y)$  modélise l'ensemble de tous les liens statistiques entre les deux processus aléatoires  $X$  et  $Y$ . Donc, il est possible d'estimer toute information sur  $X$  contenue dans l'observation  $Y$  à travers la loi *a posteriori* (Equation 3.1).

$$\begin{aligned} p(x|y) &= \frac{p(x,y)}{p(y)} \\ &= \frac{p(y|x)p(x)}{p(y)} \\ &\propto p(y|x)p(x) \end{aligned} \tag{3.1}$$

Il est à noter qu'en statistique bayésienne, les lois de probabilité  $p(x)$ ,  $p(y)$  et  $p(y|x)$  expriment respectivement la loi *a priori*, la loi d'observation et la loi du "bruit". Ces lois permettent le calcul de la loi *a posteriori* (Equation 3.1).

Nous décrivons, dans la partie suivante, les estimateurs bayésiens utilisés pour l'estimation du processus caché.



### 3.1.1 Estimateurs Bayésiens

L'application d'une règle de décision bayésienne permet l'estimation du processus caché  $X$  à partir du processus observé  $Y$ . Cette règle de décision dépend d'une fonction de perte  $L : \Omega^N \times \Omega^N \rightarrow \mathbb{R}^+$  (l'équation 3.2).

$$\forall(x, \hat{x}) \in \Omega^N \times \Omega^N, \begin{cases} L(x, \hat{x}) = 0 \text{ si } x = \hat{x} \\ L(x, \hat{x}) = \lambda_{x, \hat{x}} \text{ si } x \neq \hat{x} \end{cases} \quad (3.2)$$

Cette fonction de perte pénalise une mauvaise estimation de la vraie valeur du processus caché (vérité terrain). Un score de perte  $\lambda_{x, \hat{x}}$  est associé à chaque estimation  $\hat{x}$  au lieu de  $x$ .

La minimisation de la perte moyenne conditionnellement à  $Y$  permet de définir l'estimateur bayésien optimal de  $X$  qui correspond à la fonction de perte  $L$ .

$$\begin{aligned} \hat{x}_{bayésien}(y) &= \arg \min_{\hat{x} \in \Omega^N} \mathbb{E}[L(X = x, \hat{x})|Y = y] \\ &= \arg \min_{\hat{x} \in \Omega^N} \sum_{x \in \Omega^N} L(X = x, \hat{x})p(X = x|Y = y) \end{aligned} \quad (3.3)$$

Dans les parties suivantes, nous rappelons les deux estimateurs les plus connus basés sur les deux fonctions de pertes les plus utilisées en traitement d'images.

#### 3.1.1.1 Maximum a posteriori (MAP)

Dans le cas où la fonction de perte pénalise de la même manière toutes les estimations  $\hat{x}$  différentes de la vraie valeur de  $x$ , la stratégie MAP (en anglais Maximal A Posteriori) est appliquée. La fonction de perte est définie comme suit :

$$\forall(x, \hat{x}) \in \Omega^N \times \Omega^N, L_{MAP}(x, \hat{x}) = \mathbf{1}_{x \neq \hat{x}} \quad (3.4)$$

Donc, l'estimateur bayésien MAP est donné par la formule :

$$\hat{x}_{MAP}(y) = \arg \max_{x \in \Omega^N} p(X = x|Y = y) \quad (3.5)$$

Cet estimateur maximise la probabilité *a posteriori* ce qui favorise l'obtention de la bonne configuration  $x$  la plus attachée aux observations  $y$ . Cependant, cet estimateur peut être considéré comme brutal car il ne fait aucune différence entre une configuration avec un seul pixel mal classé et d'autres configurations bien plus mauvaises.

### 3.1.1.2 Mode des Marginales a posteriori (MPM)

Contrairement à la stratégie MAP, la stratégie MPM (en anglais Maximum Posteriori Mode) pénalise l'estimation  $\hat{x}$  de manière proportionnelle au nombre des pixels mal classés. La fonction de perte associée à cette stratégie est exprimée comme suit :

$$\forall (x, \hat{x}) \in \Omega^N \times \Omega^N, L_{MPM}(x, \hat{x}) = \sum_{n=1}^N \mathbf{1}_{x_n \neq \hat{x}_n} \quad (3.6)$$

Donc, l'estimateur MPM est donné par la formule :

$$\forall x_n \in \{1, \dots, N\}, \hat{x}_{n_{MPM}}(y) = \arg \max_{x_n \in \Omega} p(X_n = x_n | Y = y) \quad (3.7)$$

Notre but est de rechercher des régions bien définies dans l'image dégradée de l'iris et la présence de quelques mauvaises classifications des pixels peut être négligée. Notre préoccupation est de minimiser le taux des pixels mal classés dans l'image segmentée. La maximisation locale de la probabilité *a posteriori* proposée par la stratégie MPM la rend bien adaptée à ce problème.

### 3.1.2 Méthodes d'estimation des paramètres

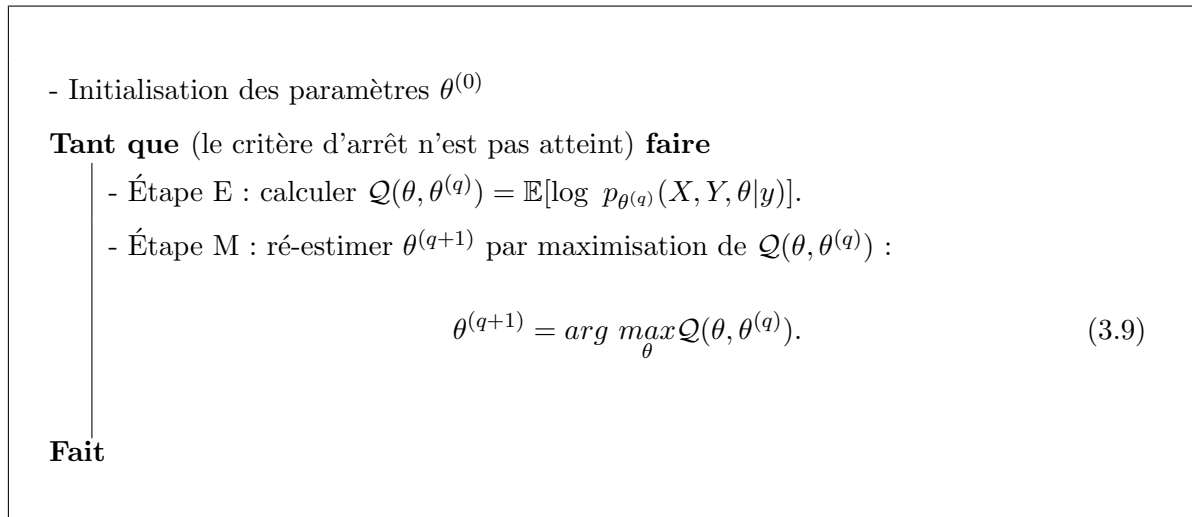
Dans le contexte de la segmentation non supervisée, nous supposons que la densité  $p(z)$  est paramétrée. Il est obligatoire d'estimer ses paramètres. Soit  $\theta = \{\theta_1, \theta_2, \dots, \theta_m\}$  l'ensemble des paramètres de la loi de  $Z$ ,  $P_\theta(\mathbf{X}, \mathbf{Y})$ . Nous supposons que ces paramètres peuvent être estimés dans le cas des variables latentes et à partir seulement de la réalisation observée  $y$  de  $Y$ . Il est bien connu qu'il existe de nombreuses méthodes d'estimation des paramètres. Nous présentons par la suite les algorithmes les plus utilisés dans le cas des chaînes markoviennes : Espérance-Maximisation (en anglais Expectation-Maximisation ou EM (11), (49), (139), (84)), sa version stochastique (en anglais Stochastic Expectation-Maximisation ou SEM (28), (35), (36)) et l'estimation itérative conditionnelle (en anglais Iterative Conditionnel Estimation ou ICE (96), (99)).

### 3.1.2.1 Espérance-Maximisation (EM)

L'algorithme EM (11), (49) est, l'un des algorithmes les plus populaires, utilisé afin d'estimer les paramètres des modèles à variables cachées. Son objectif est d'estimer l'ensemble des composantes de  $\theta$  qui caractérise la loi  $P_\theta(\mathbf{X}, \mathbf{Y} = \mathbf{y})$  en maximisant une fonction de pseudo-vraisemblance écrite sous la forme suivante :

$$\mathcal{Q}(\theta, \theta^{(q)}) = \mathbb{E}[\log p_{\theta^{(q)}}(X, Y, \theta|y)]. \quad (3.8)$$

L'algorithme EM itère alternativement entre deux étapes : étape d'espérance notée (E) et une étape de maximisation notée (M). Une initialisation de l'ensemble du jeu de paramètres est nécessaire pour le déroulement de l'algorithme. Son principe est décrit comme suit :



Algorithme 1: Principe de la méthode EM.

Pratiquement, le critère d'arrêt dépend d'un nombre d'itérations fixé à l'avance et/ou la stabilité de la log-vraisemblance au seuil  $\varepsilon$  qui est définie par :

$$\log p_{\theta^{(q+1)}}(y) - \log p_{\theta^{(q)}}(y) \leq \varepsilon. \quad (3.10)$$

Cet algorithme construit une séquence de paramètres  $\theta^{(q)}_{q \geq 1}$  préservant la croissance de la pseudo-vraisemblance ce qui assure la convergence de l'algorithme. Cependant, une étude menée dans (139), a montré que l'algorithme EM converge vers un point stationnaire. Dans le

cas de la présence de plusieurs points stationnaires, sa convergence dépend fortement du jeu de paramètres initial. Par ailleurs, cet algorithme présente une faible vitesse de convergence et dans certains cas, le calcul analytique de la fonction  $Q(\theta, \theta^{(q)})$  est difficile voir même impossible.

### 3.1.2.2 Espérance-Maximisation Stochastique (SEM)

L'algorithme SEM est une variante stochastique de l'algorithme de référence EM. Il a été introduit pour la première fois dans (28) afin de corriger les limitations de convergence de l'algorithme EM. En plus, il remplace la fonction d'intérêt  $Q(\theta, \theta^{(q)})$  (impossible à évaluer dans certains cas) dans l'étape E de la l'algorithme EM par sa moyenne empirique ce qui facilite son calcul.

Contrairement à l'algorithme EM, cet algorithme comprend en plus une étape stochastique (étape S) qui précède l'étape E. Cette étape permet d'introduire une perturbation stochastique en se basant sur le principe d'attribution aléatoire (en anglais Stochastic Imputation Principle (37)). Ce dernier génère des échantillons pseudo-complets par un tirage des échantillons cachés à partir de leurs densités conditionnellement aux observations. À chaque itération  $q$ , la ré-estimation des paramètres  $\theta^{(q)}$  est réalisée par l'application de l'estimateur de maximum de vraisemblance sur l'échantillon  $\mathbf{x}^{(q-1)}$  simulé suivant la loi *a posteriori*  $P_{\theta^{(q-1)}}(\mathbf{X}|\mathbf{Y} = \mathbf{y})$ .

La convergence de cet algorithme a été étudiée dans le cas d'identification de mélanges finis de densités (34) et dans le cas d'estimation de mélanges généralisés dans les arbres de Markov cachés (88). Les auteurs des ces deux travaux ont montré que les perturbations induites par les simulations stochastiques limitent la convergence vers une solution locale comme c'est le cas pour l'algorithme EM. En plus, l'avantage principal est que l'algorithme SEM est moins sensible à l'initialisation et qu'il est plus rapide que l'algorithme EM.

Une variante de l'algorithme SEM a été proposée dans (14). Le principe général est le même mais la manière de simuler la réalisation  $x^{(q-1)}$  de  $X$  à chaque itération ( $q - 1$ ) est différente. Au lieu de simuler en fonction de la distribution *a posteriori*  $P_{\theta^{(q-1)}}(\mathbf{X}|\mathbf{Y} = \mathbf{y})$ , les composantes  $(x_1^{(q-1)}, \dots, x_N^{(q-1)})$ , de la réalisation  $\mathbf{x}^{(q-1)}$  utilisée pour la ré-estimation des

paramètres  $\theta^{(q)}$ , sont obtenues par une simulation indépendante de réalisations de chaque couple  $(x_n^{(q-1)}, x_{n+1}^{(q-1)})$  suivant la distribution *a posteriori*  $P_{\theta^{(q-1)}}(X_n, X_{n+1} | \mathbf{Y} = \mathbf{y})$ .

Les auteurs ont montré que dans certains cas, cette variante s'avère légèrement plus performante que l'algorithme EM mais la convergence est cependant plus longue.

### 3.1.2.3 Estimation Conditionnelle Itérative (ICE)

Contrairement à l'algorithme EM et ses variantes basées sur le calcul de la vraisemblance, l'algorithme itératif ICE introduit dans (96) est une méthode générale d'estimation des paramètres. En effet, l'algorithme ICE ne cherche pas à estimer une approximation du maximum de vraisemblance. Il consiste à générer une suite de paramètres  $\theta^{(q)}_{q \geq 1}$ . Son principe est basé sur le calcul d'un estimateur  $\hat{\theta}(X, Y)$  défini sur les données complètes,  $Z$ , conditionnellement aux données observées  $Y$ . Au sens de l'erreur quadratique moyenne, la meilleure approximation est l'espérance conditionnelle par rapport à  $Y$  notée  $\mathbb{E}[\hat{\theta}(Z) | Y = y]$  qui dépend de  $\theta$ . L'évaluation du paramètre  $\theta^{(q+1)}$  se fait d'une manière itérative comme suit :

$$\theta^{(q+1)} = \mathbb{E}_{\theta^{(q)}}[\hat{\theta}(Z) | Y = y]. \quad (3.11)$$

L'espérance conditionnelle peut être approchée par sa moyenne empirique (Équation 3.12) lorsqu'elle n'est pas explicitement calculable mais la simulation des réalisations  $\{x_1, \dots, x_n\}$  de  $X$  selon la loi *a posteriori* est possible.

$$\theta^{(q+1)} = \frac{1}{n} \sum_{i=1}^n \hat{\theta}(x_i^{(q)}, y). \quad (3.12)$$

L'utilisation de n'importe quel estimateur  $\hat{\theta}(X, Y)$  par la méthode ICE est considéré comme le principal avantage de cette dernière. En effet, il la rend plus souple et générale. Par ailleurs, dans le cas où l'estimateur utilisé est l'estimateur de maximum de vraisemblance avec un changement de l'ordre des étapes de maximisation et le calcul de l'espérance conditionnelle, l'algorithme ICE se différencie peu de l'algorithme EM, voir pas du tout (48).

Le déroulement de l'algorithme ICE se fait comme suit :

```

- Initialisation des paramètres  $\theta^{(0)}$ 
Tant que (le critère d'arrêt n'est pas atteint) faire
  | - Calculer  $\theta^{(q+1)}$  par :
  | Si ( $\mathbb{E}_{\theta^{(q)}}\{\hat{\theta}(Z)|Y = y\}$  est calculable) Alors
  | | - Équation 3.11
  | Sinon
  | | ;
  | Fin Si
  | - Équation 3.12;
Fait

```

Algorithme 2: Principe de la méthode ICE.

Comme pour l'algorithme EM, le critère d'arrêt de l'algorithme ICE dépend de la stabilité des valeurs estimées.

En résumé, nous avons présenté dans cette partie le concept de la segmentation non supervisée par des approches bayésiennes. L'ensemble des approches présentées fonctionnent en trois étapes. La première étape consiste à produire un jeu de paramètres initial du modèle  $\theta^{(0)}$ . Ce dernier est obtenu à partir de la réalisation  $x^{(0)}$  résultant par exemple, de l'application d'une méthode de segmentation rapide à titre d'exemple l'algorithme Kmeans. La deuxième étape permet l'estimation d'un jeu de paramètres optimal caractérisant le modèle utilisé selon le principe d'une des méthodes d'estimation de paramètres citées auparavant (EM, SEM et ICE). La troisième étape consiste à restaurer le processus caché par l'un des estimateurs bayésiens (MAP ou MPM).

Notre étude des différentes approches bayésiennes nous a permis d'adopter la stratégie MPM et l'algorithme SEM dans ce travail dans le but d'obtenir des méthodes de segmentation non supervisée des images dégradées d'iris. Ce choix est basé d'une part sur le fait que la stratégie MPM est bien adaptée au problème de segmentation d'images car elle pénalise localement les mauvaises classifications. D'autre part, les travaux (34) et (88) considèrent

que l'algorithme SEM est généralement plus rapide avec un léger avantage par rapport aux autres méthodes classiques. Nous développons la stratégie MPM et l'algorithme SEM pour chaque modèle markovien décrit par la suite dans ce manuscrit.

## 3.2 Chaînes Markov Cachées

La revue des approches statistiques dans la littérature a montré que les chaînes de Markov cachées (en anglais Hidden Markov Chain (HMC)) figurent parmi les modèles les plus utilisés dans différents domaines (27), (26), (42), (17), (31). Cette diversité d'utilisation est due à sa capacité de s'adapter aux différentes situations. En effet, il est possible d'appliquer les approches bayésiennes et les méthodes d'estimation de paramètres citées auparavant. Le but de cette section est de décrire le modèle HMC ainsi que la méthode de restauration d'une HMC et la méthode d'estimation des paramètres réalisée dans ce travail.

### 3.2.1 Définition du modèle

Soit  $X = (X_n)_{n=1}^N$  un processus caché qui prend ses valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_K\}$ , et soit  $Y = (Y_n)_{n=1}^N$  un processus observé qui prend ses valeurs dans  $\mathbb{R}$ . Le processus  $Y$  peut être considéré comme une version bruitée de  $X$ . La loi  $p(y|x)$  est dite distribution de bruit.

Le modèle HMC (Équation 3.13) (10) consiste à considérer  $X$  comme une chaîne de Markov. Nous supposons que les observations  $Y$  sont indépendantes conditionnellement aux variables cachées  $X$ , nous parlons des HMCs à bruit indépendant.

$$\begin{cases} p(x) = p(x_1) \prod_{n=1}^{N-1} p(x_{n+1}|x_n). \\ p(y|x) = \prod_{n=1}^N p(y_n|x_n). \end{cases} \quad (3.13)$$

Selon ce modèle, la probabilité jointe de  $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$  est donnée par :

$$p(\mathbf{z}) = p(x_1)p(y_1|x_1) \prod_{n=1}^{N-1} p(x_{n+1}|x_n)p(y_{n+1}|x_{n+1}). \quad (3.14)$$

Dans la suite de ce travail, nous ferons l'hypothèse que pour tout  $n \in \{1, \dots, N\}$ ,  $p(y_n|x_n)$  est une loi gaussienne et nous considererons le cas des HMCs à bruit indépendant. Alors, la distribution de  $Z = (X, Y)$  sera dite chaîne de Markov cachée gaussienne. Dans le reste du texte, la notation HMC signifie une chaîne de Markov cachée gaussienne.

### 3.2.2 Estimation des paramètres d'une HMC

Lorsque l'ensemble de paramètres  $\theta$  n'est pas connu, il existe plusieurs méthodes pour l'estimer. Nous avons décrit dans la section 3.1.2 les principales méthodes d'estimation des paramètres. Dans le cas d'une HMC, l'ensemble de paramètres  $\theta$  est défini par :

- La loi initiale  $p(x_1) = \pi$  où  $\pi_i = p\{x_1 = \omega_i\}$ .
- La matrice de transition  $\mathcal{C}$  où  $c_{ij} = p(x_{n+1} = \omega_j|x_n = \omega_i)$  représente la probabilité de transition de l'état  $i$  à l'état  $j$ .
- Les paramètres des lois gaussiennes représentés par  $\mu = \{\mu_1, \dots, \mu_k\}$  et  $\sigma = \{\sigma_1, \dots, \sigma_k\}$ .

Les paramètres du modèle HMC sont les probabilités initiales  $\pi_i$  et les probabilités de transition  $c_{ij}$  et ils sont au nombre de  $(K^2 - 1) + (K - 1)$ . Ces paramètres peuvent être déduits à partir de la probabilité jointe  $p(x_n = \omega_i, x_{n+1} = \omega_j)$ . Donc au lieu d'estimer  $(K^2 - 1) + (K - 1)$  paramètres, il suffit juste d'estimer  $(K^2 - 1)$  probabilités  $p(x_n = \omega_i, x_{n+1} = \omega_j)$ . Les paramètres des lois gaussiennes décrivent les paramètres de la distribution du bruit et leur nombre est égal à  $2K$ . Au total, il faut estimer  $(K^2 - 1) + 2K$  paramètres.



- Initialisation des paramètres  $\theta^{(0)} = \{\pi^0, \mathcal{C}^0, \mu^0, \sigma^0\}$

**Tant que** (le critère d'arrêt n'est pas atteint) **faire**

- Étape S : Simulation d'une réalisation  $x^{(q)} = \{x_1^{(q)}, \dots, x_N^{(q)}\}$  selon la loi *a posteriori*  $p(x|y, \theta^{(q)})$

- Étape E : Déduire la fonction  $\mathcal{Q}(\theta, \theta^{(q)})$

$$\mathcal{Q}(\theta, \theta^{(q)}) = \frac{1}{N} \sum_{n=1}^N p_{\theta^{(q)}}(X, Y, \theta | x^{(q)}, y) \quad (3.15)$$

- Étape M : ré-estimer  $\theta^{(q+1)}$

$$\pi_i^{(q+1)} = \frac{1}{N} \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)} \quad (3.16)$$

$$c_{ij}^{(q+1)} = \eta_1 \sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)}; \quad (3.17)$$

$$\mu_i^{(q+1)} = \eta \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)} y_n; \quad (3.18)$$

$$\sigma_i^{(q+1)} = \eta \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)} (y_n - \mu_i^{(q)})^2; \quad (3.19)$$

avec  $\eta = \frac{1}{\sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)}}$ ,  $\eta_1 = \frac{1}{\sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i)}}$  et  $(\omega_i, \omega_j) \in \Omega \times \Omega$ .

**Fait**

Algorithme 3: Principe de la méthode SEM dans une HMC.

### 3.2.3 Restauration d'une HMC

Nous considérons, dans cette partie, que le modèle HMC est bien défini et tous ses paramètres sont connus. Nous avons choisi d'utiliser l'estimateur bayésien MPM décrit dans 3.1.1.2 pour restaurer le processus aléatoire caché  $X$  à partir de la réalisation  $Y$ . Cet estimateur maximise localement la loi *a posteriori*  $p(x_n|y)$ . Cette dernière contient toute l'in-

formation sur  $X$  contenue dans les observations  $Y = y$ . Cette probabilité *a posteriori* reste calculable grâce à la méthode itérative nommée forward-backward proposée dans (11). Cette méthode consiste à calculer les probabilités forward  $\alpha_n(k) = p(x_n = \omega_k, y_{1:n})$  et les probabilités backward  $\beta_n(k) = p(y_{n+1:1} | x_n = \omega_k)$  avec  $k \in \Omega$ . Les récursivités suivantes permettent de calculer ces probabilités.

1. Probabilités forward :

$$\begin{cases} \alpha_1(k) = p(z_1) = p(x_1 = \omega_k)p(y_1 | x_1 = \omega_k); \\ \alpha_{n+1}(k) = \sum_{j \in \Omega} \alpha_n(j)p(x_{n+1} = \omega_k | x_n = \omega_j)p(y_{n+1} | x_{n+1} = \omega_k). \end{cases} \quad (3.20)$$

2. Probabilités backward :

$$\begin{cases} \beta_N(k) = 1; \\ \beta_n(k) = \sum_{j \in \Omega} \beta_{n+1}(j)p(x_{n+1} = \omega_j | x_n = \omega_k)p(y_{n+1} | x_{n+1} = \omega_j). \end{cases} \quad (3.21)$$

Il est très fréquent que ces probabilités prennent des valeurs nulles lors du traitement des chaînes de grande taille. Pour éviter ce phénomène, une solution basée sur le « rescaling » (53) nécessite la normalisation de ces probabilités à chaque itération.

Les probabilités forward et backward permettent le calcul des probabilités de transition *a posteriori* données par :

$$\begin{aligned} \forall n \in \{1, \dots, N-1\} \text{ et } \forall (\omega_i, \omega_j) \in \Omega \times \Omega; \\ p(x_{n+1} = \omega_j | x_n = \omega_k, y) = \frac{p(x_{n+1} = \omega_j | x_n = \omega_k)p(y_{n+1} | x_{n+1} = \omega_j)\beta_{n+1}(x_{n+1} = \omega_j)}{\beta_n(x_n = \omega_k)}; \end{aligned} \quad (3.22)$$

et la marginale *a posteriori* exprimée par :

$$p(x_n = \omega_k | y) = \frac{\alpha_n(x_n = \omega_k)\beta_n(x_n = \omega_k)}{\sum_{x'_n \in \Omega} \alpha_n(x'_n)\beta_n(x'_n)}. \quad (3.23)$$

Le calcul de cette dernière offre la possibilité de calculer la décision bayésienne MPM et par conséquent une restauration du processus caché  $X$ . De plus, la probabilité marginale

*a posteriori* est utilisée dans l'étape S de la méthode SEM pour simuler des réalisations *a posteriori* lors de l'estimation des paramètres dans le cas où ces derniers sont inconnus.

### 3.3 Chaînes Markov Couples

Nous avons détaillé dans la section précédente le modèle HMC qui fait l'hypothèse d'indépendance conditionnelle des observations  $Y$  par rapport au processus caché  $X$ . Cependant, cette hypothèse n'est pas toujours justifiable en pratique et dans certains cas réels, il est intéressant de prendre en considération les différentes interactions entre les différents pixels voisins. Pour répondre à ce problème, le modèle de chaîne de Markov couple (en anglais Pairwise Markov Chain (PMC)) a été introduit par Pieczynski dans son travail (97) et développé dans le cadre de la segmentation non supervisée d'images par Derrode et Pieczynski dans (50). Le modèle PMC est une version plus générale et donc plus riche que le modèle HMC. Il considère que le processus caché  $X$  n'est pas obligatoirement markovien et le couple  $Z = (X, Y)$  est markovien. Le modèle PMC sera précisé par la suite.

#### 3.3.1 Définition du modèle

Nous considérons la vecteur aléatoire  $X = (X_n)_{n=1}^N$  comme un processus caché prenant ses valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_K\}$ , et  $Y = (Y_n)_{n=1}^N$  comme un processus observé discret (chaque  $Y_n \in \mathbb{R}$ ). Si la loi jointe de  $Z = (X, Y)$  est Markovienne alors le couple  $(X, Y)$  est dit PMC.

Selon le modèle PMC, la probabilité jointe est donnée par :

$$p(z) = p(z_1) \prod_{n=1}^{N-1} p(z_{n+1}|z_n). \quad (3.24)$$

Sans aucune perte de généralité, la probabilité de transition est donnée par :

$$\begin{aligned} p(z_{n+1}|z_n) &= p(x_{n+1}, y_{n+1}|x_n, y_n) \\ &= p(x_{n+1}|x_n, y_n)p(y_{n+1}|x_{n+1}, x_n, y_n) \end{aligned} \quad (3.25)$$

Alors, nous pouvons facilement déduire que le modèle HMC défini par l'équation 3.14 est un cas particulier du modèle PMC dans lequel :

$$\begin{cases} p(x_{n+1}|x_n, y_n) = p(x_{n+1}|x_n) \\ p(y_{n+1}|x_{n+1}, x_n, y_n) = p(y_{n+1}|x_{n+1}) \end{cases} \quad (3.26)$$

L'équation 3.26 montre que le modèle PMC est plus général que le modèle HMC.

Dans cette partie, nous avons considéré exclusivement le modèle PMC stationnaire pour lequel  $p(z_{n+1}|z_n)$  ne dépend pas de  $n$ . Dans ce modèle, la distribution  $Z$  est définie par :

$$p(z_n, z_{n+1}) = p(x_n = \omega_i, x_{n+1} = \omega_j) f_{\omega_i, \omega_j}(y_n, y_{n+1}) \quad (3.27)$$

où  $p(x_1 = \omega_n, x_{n+1} = \omega_j)$  sont les probabilités définies sur  $\Omega^2$  et  $f_{i,j}(y_n, y_{n+1})$  sont les densités définies sur  $\mathbb{R}^2$ .

Sachant que  $Z$  est une chaîne de Markov, on peut alors définir cette distribution à l'aide des probabilités initiales et celles de transitions d'après :

$$\begin{cases} p(z_1) &= \sum_{\omega_j \in \Omega} p(\omega_i, \omega_j) \int^R f_{\omega_i, \omega_j}(y_1, y_2) dy_2, \quad i \in \Omega \\ &= \sum_{\omega_j \in \Omega} p(\omega_i, \omega_j) f_{\omega_i, \omega_j}(y_1), \\ p(z_{n+1}|z_n) &= \frac{p(z_n, z_{n+1})}{p(z_n)} \\ &= \frac{p(x_n = \omega_i, x_{n+1} = \omega_j) f_{\omega_i, \omega_j}(y_n, y_{n+1})}{\sum_{k \in \Omega} p(x_n = \omega_i, x_{n+1} = \omega_k) f_{\omega_i, \omega_k}(y_n)}, \quad (\omega_i, \omega_j) \in \Omega \times \Omega \end{cases} \quad (3.28)$$

### 3.3.2 Estimation des paramètres d'une PMC

Nous avons fait l'hypothèse que la densité du bruit suit une loi normale bidimensionnelle. Dans ce cas, nous traitons un modèle PMC gaussien. Ce modèle est complètement défini par les paramètres suivants :

- $K^2$  probabilités  $p(\omega_i, \omega_j)$  avec  $(\omega_i, \omega_j) \in \Omega \times \Omega$ .
- $K^2$  densités normales bidimensionnelles  $p(y_n, y_{n+1}|x_n = i, x_{n+1} = j)$  notées  $f_{\omega_i, \omega_j}(y_n, y_{n+1})$  qui représentent les densités du bruit.

Les densités du bruit sont définies par les moyennes  $\mu_1^{ij}$  et  $\mu_2^{ij}$  (avec  $(i, j) \in 1, \dots, K^2$ ) stockées dans le vecteur  $\mu^{ij}$ , les écart-types  $\sigma_1^{ij}$  et  $\sigma_2^{ij}$  et le coefficient de corrélation  $\rho^{ij}$  entre

les deux classes  $i$  et  $j$  stockés dans la matrice de variances-covariances  $\Sigma^{ij}$ . Au total, il faut estimer  $6K^2 - 1$  paramètres.

Dans cette section, tous ces paramètres sont considérés inconnus et doivent être estimés à partir de l'observation  $Y = y$ . Nous avons choisi d'utiliser la variante de la méthode SEM. Le principe de cette dernière est décrit dans l'algorithme 4.

- Initialisation des paramètres  $\theta^{(0)} = \{p_{ij}^{(0)}, (\mu^{ij})^{(0)}, (\Sigma^{ij})^{(0)}\}$ .

**Tant que** (le critère d'arrêt n'est pas atteint) **faire**

- Étape MS : Simulation indépendante des réalisations de chaque couple  $(x_n^{(q)}, x_{n+1}^{(q)})$  suivant la distribution *a posteriori*  $P_{\theta^{(q)}}(X_n, X_{n+1} | \mathbf{Y} = \mathbf{y})$  afin de construire les composantes de  $x^{(q)} = \{x_1^{(q)}, \dots, x_N^{(q)}\}$ .

- Étape E : Déduire la fonction  $\mathcal{Q}(\theta, \theta^{(q)})$  :

$$\mathcal{Q}(\theta, \theta^{(q)}) = \frac{1}{N-1} \sum_{n=1}^{N-1} p_{\theta^{(q)}}(X, Y, \theta | x^{(q)}, y). \quad (3.29)$$

- Étape M : ré-estimer  $\theta^{(q+1)}$

$$p_{ij}^{(q+1)} = \frac{1}{N} \sum_{n=1}^N \mathbf{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)} \quad (3.30)$$

$$(\mu^{ij})^{(q+1)} = \eta \sum_{n=1}^{N-1} \mathbf{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)} \begin{pmatrix} y_n \\ y_{n+1} \end{pmatrix} \quad (3.31)$$

$$(\Sigma^{ij})^{(q+1)} = \eta \sum_{n=1}^{N-1} \mathbf{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)} \left( \begin{pmatrix} y_n \\ y_{n+1} \end{pmatrix} - (\mu^{ij})^{(q+1)} \right) \left( \begin{pmatrix} y_n \\ y_{n+1} \end{pmatrix} - (\mu^{ij})^{(q+1)} \right)^t \quad (3.32)$$

avec  $\eta = \frac{1}{\sum_{n=1}^{N-1} \mathbf{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)}}$  et  $(\omega_i, \omega_j) \in \Omega \times \Omega$ .

**Fait**

Algorithme 4: Principe de la variante de la méthode SEM dans un PMC.

### 3.3.3 Restauration d'une PMC

La restauration du processus caché  $X$  à partir du processus observé  $Y$  est réalisée par l'application de la méthode MPM (Section 3.1.1.2). Les auteurs de (50) ont généralisé l'algorithme Baum-Welch (53) et la méthode forward-backward au modèle PMC. Le calcul de la probabilité *a posteriori*  $p(x_n|y)$  est déduit à partir des probabilités forward-backward (Équation 3.36). Ces dernières sont définies par :  $\alpha_n(\omega_k) = p(x_n = \omega_k, y_{1:n})$  et  $\beta_n(\omega_k) = p(y_{n+1:1}|x_n = \omega_k, y_n)$  avec  $\omega_k \in \Omega$  et calculées récursivement selon :

1. Probabilités forward :

$$\begin{cases} \alpha_1(\omega_k) = p(z_1) = p(x_1 = \omega_k)p(y_1|x_1 = \omega_k); \\ \alpha_{n+1}(\omega_k) = \sum_{j \in \Omega} \alpha_n(j)p(x_{n+1} = \omega_k, y_{n+1}|x_n = \omega_j, y_n) \end{cases} \quad (3.33)$$

2. Probabilités backward :

$$\begin{cases} \beta_N(\omega_k) = 1; \\ \beta_n(\omega_k) = \sum_{j \in \Omega} \beta_{n+1}(j)p(x_{n+1} = j, y_{n+1}|x_n = \omega_k, y_n) \end{cases} \quad (3.34)$$

Donc, la probabilité de transition *a posteriori* est donnée par :

$$p(x_{n+1}|x_n, y) = \frac{p(z_{n+1}|z_n)\beta_{n+1}(x_{n+1})}{\beta_n(x_n)} \quad (3.35)$$

Et la marginale *a posteriori* est donnée par :

$$p(x_n = \omega_k|y) = \frac{\alpha_n(x_n = \omega_k)\beta_n(x_n = \omega_k)}{\sum_{x'_n \in \Omega} \alpha_n(x'_n)\beta_n(x'_n)} \quad (3.36)$$

## 3.4 Chaînes Markov Triplets

Jusqu'ici nous avons fait l'hypothèse que le processus caché est stationnaire. Effectivement, dans ce cadre, les paramètres ainsi que le processus caché peuvent être estimés. En réalité, cette hypothèse n'est pas toujours vérifiée ce qui se traduit dans certains cas par une mauvaise

restauration du processus caché. Pour résoudre ce problème, une généralisation des modèles HMC et PMC aux chaînes de Markov triplets (en anglais Triplet Markov Chain (TMC)) a été proposée dans le travail (100). L'auteur propose d'ajouter un processus auxiliaire  $U$  qui permet la modélisation des différentes stationarités du processus caché en supposant la markovianité du triplet  $T = (X, U, Y)$ .

Dans le cadre général des TMC, il faut noter que la loi jointe donnée par l'équation 3.37 est la même que celle donnée par le modèle PMC (Équation 3.24), si nous posons  $V = (U, X)$  (98). Cette généralisation conduit à la naissance d'une famille de modèles TMC, dans laquelle nous trouvons la chaîne de Markov non stationnaire cachée proposée par Lachantin dans (74). Cette dernière consiste à modéliser la non stationnarité du processus caché par l'utilisation du processus auxiliaire  $U$  tout en considérant le couple  $V = (X, U)$  markovien et la loi de  $Y$  conditionnelle à  $V$  notée  $p(y|x) = \prod_{n=2}^N p(y_n|x_n)$ . D'autres cas particuliers de modèles triplets ont été étudiés dans (12), (98), (73), (24), (22), etc.

Notre but est de segmenter des images dégradées d'iris où il est très fréquent que certains pixels de l'image qui appartiennent à la même région apparaissent avec des niveaux de gris très différents à cause des effets résultants de l'acquisition non contrôlée (par exemple le problème d'illumination). Dans ce cas, la loi *a priori* qui modélise l'émission des classes (régions) est stationnaire contrairement à celle de la loi de distribution du bruit qui est non stationnaire. Pour cette raison, nous souhaitons utiliser un modèle de la famille des modèles TMC nommé HMC à bruit M-stationnaire proposé dans (21), (20) pour modéliser ce phénomène. Pour simplifier sa notation, nous utilisons l'abréviation TMC. Dans la section suivante, nous spécifierons sa modélisation mathématique et nous détaillerons l'adaptation de la méthode d'estimation de paramètres et la restauration du processus caché dans ce contexte.

### 3.4.1 Définition du modèle

Nous considérons deux processus aléatoires,  $X = (X_n)_{n=1}^N$  comme un processus caché prenant ses valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_K\}$ , et  $Y = (Y_n)_{n=1}^N$  comme un processus observé prenant ses valeurs dans  $\mathbb{R}$ . On définit également un processus auxiliaire discret  $U$  qui prend ses valeurs dans  $\Lambda = \{\lambda_1, \dots, \lambda_M\}$ . Le triplet  $T = (U, X, Y)$  suit une loi

de Markov donc  $T$  est une TMC.

Selon le modèle TMC (HMC à bruit M-stationnaire), la probabilité jointe  $T = (U, X, Y)$  est définie par :

$$p(\mathbf{t}) = p(t_1) \prod_{n=1}^{N-1} p(t_{n+1}|t_n) \quad (3.37)$$

Avec :

$$\begin{cases} p(t_1) = p(u_1)p(x_1)p(y_1|u_1, x_1) \\ p(t_{n+1}|t_n) = p(u_{n+1}|u_n)p(x_{n+1}|x_n)p(y_{n+1}|u_{n+1}, x_{n+1}) \end{cases} \quad (3.38)$$

### 3.4.2 Estimation des paramètres

Nous montrons dans cette section comment nous estimons les paramètres du modèle TMC dans le cas où ils sont inconnus. Nous considérons que le modèle est défini par :

- La loi initiale  $p(x_1) = \pi$  où  $\pi_i = p\{x_1 = \omega_i\}$ .
- La matrice de transition  $\mathcal{C}$  où  $c_{\omega_i \omega'_i} = p(x_{n+1} = \omega'_i | x_n = \omega_i)$  représente la probabilité de transition de l'état  $\omega_i$  à l'état  $\omega'_i$ .
- La loi initiale  $p(u_1) = \varpi$  où  $\varpi_j = p\{u_1 = \lambda_j\}$ .
- La matrice de transition  $\mathcal{A}$  où  $a_{\lambda_j \lambda'_j} = p(u_{n+1} = \lambda'_j | u_n = \lambda_j)$  représente la probabilité de transition de l'état  $\lambda_j$  à l'état  $\lambda'_j$ .
- Les distributions du bruit  $p(y_n | x_n = i, u_n = j)$ , qui sont définies par des lois gaussiennes, sont représentées par les moyennes  $\mu_{ij}$  et les écart-types  $\sigma_{ij}$ .

Les probabilités initiales de transitions peuvent être estimées directement à partir de la loi jointe. Donc, il y a  $(K^2 - 1) + (M^2 - 1)$  paramètres qui modélisent les lois de  $X$  et de  $U$ . En plus, il existe  $M \times K$  distributions du bruit, donc elles sont représentées par  $2 \times M \times K$  paramètres. Au total, ce modèle comporte  $(K^2 - 1) + (M^2 - 1) + 2 \times M \times K$  paramètres. Dans le cas d'une TMC, le principe de SEM est décrit dans l'algorithme 5.



- Initialisation des paramètres  $\theta^{(0)} = \{\pi^0, \varpi^0, C^0, \mathcal{A}^0, \mu_{ij}^0, \sigma_{ij}^0\}$

**Tant que** (le critère d'arrêt n'est pas atteint) **faire**

- Étape S : Simulation des réalisations  $x^{(q)} = \{x_1^{(q)}, \dots, x_N^{(q)}\}$  et  $u^{(q)} = \{u_1^{(q)}, \dots, u_N^{(q)}\}$  selon les lois *a posteriori*  $p(x|y, \theta^{(q)})$  et  $p(u|y, \theta^{(q)})$  respectivement.

- Étape E : Déduire la fonction  $\mathcal{Q}(\theta, \theta^{(q)})$

$$\mathcal{Q}(\theta, \theta^{(q)}) = \frac{1}{N} \sum_{n=1}^N p_{\theta^{(q)}}(X, Y, \theta | x^{(q)}, y) \quad (3.39)$$

- Étape M : ré-estimer  $\theta^{(q+1)}$

$$\pi_i^{(q+1)} = \frac{1}{N} \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)}; \quad (3.40)$$

$$\varpi_j^{(q+1)} = \frac{1}{N} \sum_{n=1}^N \mathbb{1}_{(u_n^{(q)} = \lambda_j)}; \quad (3.41)$$

$$c_{ii'}^{(q+1)} = \kappa_1 \sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_{i'})}; \quad (3.42)$$

$$a_{jj'}^{(q+1)} = \kappa_2 \sum_{n=1}^{N-1} \mathbb{1}_{(u_n^{(q)} = \lambda_j, u_{n+1}^{(q)} = \lambda_{j'})}; \quad (3.43)$$

$$\mu_{ij}^{(q+1)} = \eta \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i, u_n^{(q)} = \lambda_j)} y_n \quad (3.44)$$

$$\sigma_{ij}^{(q+1)} = \eta \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i, u_n^{(q)} = \lambda_j)} (y_n - \mu_{ij}^{(q)})^2 \quad (3.45)$$

avec  $\kappa_1 = \frac{1}{\sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i)}}$  ;  $\kappa_2 = \frac{1}{\sum_{n=1}^{N-1} \mathbb{1}_{(u_n^{(q)} = \lambda_j)}}$  ;

$\eta = \frac{1}{\sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i, u_n^{(q)} = \lambda_j)}}$  ;  $(i, i') \in \Omega \times \Omega$  et  $(\lambda_j, \lambda_{j'}) \in \Lambda \times \Lambda$

**Fait**

Algorithme 5: Principe de la méthode SEM dans un TMC.

### 3.4.3 Restauration des chaînes de Markov triplets

Suite à l'étape précédente, nous montrons comment nous pouvons estimer le processus caché  $X$  et le processus auxiliaire  $U$  à partir des observations  $Y = y$ . Nous avons choisi d'utiliser l'estimateur MPM défini par l'équation 3.7. L'application de ce dernier est possible et sa complexité est proportionnelle à  $N$  (la longueur de la chaîne  $Y$ ) (21). Comme pour le modèle PMC, l'utilisation de la méthode forward-backward est possible. Les probabilités forward  $\alpha_n(\omega_i, \lambda_j) = p(x_n = \omega_i, u_n = \lambda_j, y_{1:n})$  et les probabilités backward  $\beta_n(\omega_i, \lambda_j) = p(y_{n+1:1} | x_n = \omega_i, u_n = \lambda_j)$  avec  $(\omega_i, \lambda_j) \in \Omega \times \Lambda$  sont calculées récursivement comme suit :

1. Probabilités forward :

$$\left\{ \begin{array}{l} \alpha_1(\omega_i, \lambda_j) = p(u_1 = \lambda_j)p(x_1 = \omega_i)p(y_1 | u_1 = \lambda_j, x_1 = \omega_i); \\ \alpha_{n+1}(\omega_i, \lambda_j) = \sum_{\lambda'_j \in \Lambda} \sum_{\omega'_i \in \Omega} \alpha_n(\omega'_i, \lambda'_j)p(u_{n+1} = \lambda_j | u_n = \lambda'_j)p(x_{n+1} = \omega_i | x_n = \omega'_i) \\ \quad \times p(y_{n+1} | u_{n+1} = \lambda_j, x_{n+1} = \omega_i) \end{array} \right. \quad (3.46)$$

2. Probabilités backward :

$$\left\{ \begin{array}{l} \beta_N(\omega_i, \lambda_j) = 1; \\ \beta_n(\omega_i, \lambda_j) = \sum_{\lambda'_j \in \Lambda} \sum_{\omega'_i \in \Omega} \beta_{n+1}(\lambda'_j)p(x_{n+1} = \lambda'_j | u_n = \lambda_j)p(x_{n+1} = \omega'_i | x_n = \omega_i) \\ \quad p(y_{n+1} | u_{n+1} = \lambda'_j, x_{n+1} = \omega'_i) \end{array} \right. \quad (3.47)$$

Alors, la distribution *a posteriori*  $p(u_n, x_n | y_n)$  est exprimée par :

$$p(u_n = \lambda_j, x_n = \omega_i | y) = \frac{\alpha_n(u_n = \lambda_j, x_n = \omega_i)\beta_n(u_n = \lambda_j, x_n = \omega_i)}{\sum_{\lambda'_j \in \Lambda} \sum_{\omega'_i \in \Omega} \alpha_n(u_n = \lambda'_j, x_n = \omega'_i)\beta_n(u_n = \lambda'_j, x_n = \omega'_i)} \quad (3.48)$$

Enfin, les marginales des processus caché et auxiliaire sont données par :

$$p(u_n = \lambda_j | y) = \sum_{\omega'_i \in \Omega} p(u_n = \lambda_j, x_n = \omega'_i | y) \quad (3.49)$$

$$p(x_n = \omega_i | y) = \sum_{\lambda'_j \in \Lambda} p(u_n = \lambda'_j, x_n = \omega_i | y) \quad (3.50)$$

### 3.5 Conclusion

Dans ce chapitre, nous avons décrit le fonctionnement général des approches bayésiennes. Nous travaillons dans le cadre d'une segmentation non supervisée des images dégradées d'iris. Par conséquent, nous avons présenté les méthodes de restauration du processus caché à partir du processus observé les plus utilisées dans ce domaine (MAP et MPM). Nous avons, de plus, décrit les principales méthodes d'estimation des paramètres, en l'occurrence EM, SEM et ICE. Nous avons par ailleurs décidé de retenir l'estimateur MPM et la méthode SEM puisqu'ils sont bien adaptés à notre problème. Nous avons axé notre étude sur trois modèles markoviens de généralité croissante à savoir HMC, PMC, TMC. Enfin, nous avons détaillé l'estimateur MPM et la méthode SEM pour chaque modèle.

À notre connaissance, l'utilisation des modèles généralisés (PMC et TMC) dans le cadre de la segmentation non supervisée a été validée seulement sur des images synthétiques et quelques images réelles, en particulier des images satellitaires, (50), (75), (52), (110), (23). Aucune étude n'a été réalisée sur de grandes bases de données. Un des buts de cette thèse est de tester ces modèles sur de grandes bases de données et faire une étude comparative avec le modèle basique HMC.

Dans le chapitre prochain, nous détaillerons la modélisation du système de segmentation de l'iris. Nous précisons que le module de segmentation utilisé est fondé sur une approche statistique basée sur des modèles markoviens.

## Chapitre 4

# Modélisation proposée pour la segmentation non supervisée des images de l’iris

---

<b>4.1</b>	<b>Processus de traitement complet</b>	<b>91</b>
4.1.1	Détection grossière de la région de l’iris	91
4.1.2	Conception des modèles statistiques pour la segmentation des images de l’iris	92
<b>4.2</b>	<b>Impact du parcours de l’image sur la segmentation finale</b>	<b>94</b>
4.2.1	Parcours Hilbert-Peano	94
4.2.2	Parcours Escargot	95
4.2.3	Application sur l’image de l’iris	97
4.2.4	Comparaison des segmentations	100
4.2.5	Évaluation des cercles de normalisation	105
<b>4.3</b>	<b>Impact des Méthodes d’initialisation sur la segmentation finale</b>	<b>109</b>
4.3.1	Initialisation par K-means	110
4.3.2	Initialisation par Histogramme	110
4.3.3	Évaluation des cercles de normalisation	112
<b>4.4</b>	<b>Conclusion</b>	<b>118</b>

---

DANS ce chapitre, nous décrivons l'approche que nous proposons pour la segmentation des images d'iris. Nous avons choisi d'explorer les différents modèles de chaînes de Markov exposés dans le chapitre précédent. Nous disposons de trois modèles markoviens de complexité croissante afin de réaliser une segmentation non supervisée en régions des images dégradées d'iris. Face à cet objectif, nous souhaitons répondre aux questions suivantes :

- La complexité des modèles sera-t-elle suffisante pour modéliser la richesse des images d'iris dégradées ?
- Existe-t-il des situations particulières pour qu'un modèle simple fonctionne mieux qu'un modèle complexe ? Autrement dit, est-il intéressant de chercher une bonne initialisation et faire tourner un modèle simple pour raffiner l'initialisation ou vaut-il mieux utiliser directement un modèle complexe ?

Pour commencer, nous présentons le processus de traitement complet pour la segmentation des images dégradées d'iris par les chaînes de Markov. Pour pouvoir être utilisées en segmentation d'images, ces chaînes nécessitent une vectorisation de l'observation, ce qui n'est pas le cas pour les champs de Markov. Cette opération rend le processus de traitement moins coûteux en terme de temps de calcul. Cette vectorisation dépend du type de parcours de l'image utilisé. Nous étudierons l'impact du type de parcours de l'image réalisé sur la segmentation finale par les trois modélisations. Nous avons souligné dans le chapitre précédent que la méthode d'estimation des paramètres est très sensible à l'initialisation, par conséquent, une évaluation de l'influence de la méthode d'initialisation sur le résultat final de la segmentation est accomplie. Enfin, nous présentons une étude comparative entre ces différents modèles afin de choisir la meilleure chaîne de traitement pour la segmentation non supervisée des images difficiles de l'iris. Notre apport par ce travail de thèse consiste à combiner le meilleur parcours, la meilleure méthode d'initialisation et le meilleur modèle de la chaîne de Markov. Cette contribution a été validée sur la base ICE-2005.

## 4.1 Processus de traitement complet

### 4.1.1 Détection grossière de la région de l'iris

Les différentes bases de données utilisées dans ce travail présentent des images oculaires voire même des images du visage, alors que nous focaliserons notre étude sur la segmentation de l'iris. Il est donc nécessaire de détecter grossièrement la région de l'iris pour ne garder que l'information nécessaire. Cette limitation de la zone à traiter est considérée comme un avantage important lors de l'utilisation des méthodes de segmentation non supervisées statistiques à cause de la diminution de la variance de l'échantillon à traiter par rapport à l'image originale. De plus, il est bien connu (94) que limiter la recherche des contours à la région de l'iris réduit l'erreur de localisation de ses contours. À cette fin, nous proposons d'appliquer la CHT sur la carte des contours résultante de l'application du détecteur *canny* pour localiser la pupille. Afin de réduire la sensibilité de l'algorithme CHT et de ne préserver que les "vrais" contours, nous appliquons un filtre anisotropique suivi d'une binarisation de l'image à l'aide d'un seuil adaptatif. Il est connu que le cercle avec le maximum de votes résultant de la CHT ne représente pas nécessairement le vrai contour de la pupille en raison de la présence de régions sombres (cils, sourcils, lunettes). Pour remédier à cet inconvénient, nous sélectionnons le meilleur candidat parmi les 20 premiers cercles avec les plus hauts votes. Le meilleur candidat a la plus forte somme de gradient calculée sur un ensemble de points du cercle. Ces points sont sélectionnés tous les deux pixels entre  $180^\circ$  et  $225^\circ$  et entre  $315^\circ$  et  $360^\circ$  afin d'exclure les points qui pourraient appartenir aux cils et aux paupières. Pour des raisons de clarté, nous avons seulement tracé dans la figure 4.1 le meilleur candidat (cercle rouge/foncé) sélectionné par notre méthode et le cercle avec un maximum de votes (cercle vert/clair), qui n'est pas toujours le bon.

Une fois le contour pupillaire défini, le centre de la pupille est utilisé pour localiser une région carrée telle que la longueur de chaque côté est supérieure au rayon maximal de l'iris. Cette région englobe la région totale de l'iris.

Nous précisons que pour la base CASIA-IrisV4-distance qui contient des images du visage, une localisation automatique de la région oculaire contenant les 2 yeux a été réalisée. Nous

avons utilisé le détecteur de paires des yeux AdaBoost (134), (33) implémenté en Matlab. Enfin, chaque région de l'œil (gauche ou droite) est extraite en divisant la région des deux yeux en deux parties égales.




FIGURE 4.1 – Localisation grossière de l'iris

#### 4.1.2 Conception des modèles statistiques pour la segmentation des images de l'iris

Dans cette section, nous expliquons la mise en œuvre des différents modèles : HMC, PMC et TMC pour la segmentation non supervisée des images dégradées d'iris. Nous considérons que la réalisation  $y_s$  observée présente l'intensité en niveau de gris du pixel  $s$  et la réalisation cachée  $x_s$  prend sa valeur dans l'ensemble des classes recherchées. Il faut préciser que le nombre de classes est déterminé a priori. Pour simplifier la modélisation, nous avons supposé qu'il existe quatre classes ( $K = 4$ ) à rechercher, idéalement correspondant à l'iris, la pupille, la sclera, la peau et que la distribution du bruit est une loi gaussienne. Comme la variation de l'illumination n'est pas la même pour toutes les bases de données traitées dans ce travail et est même très variable d'une base à une autre, il est très intéressant de ne pas utiliser le même nombre de classes du processus auxiliaire lors de la segmentation par le modèle TMC. Nous avons considéré deux classes dans le cas de la segmentation des images de la bases ICE-2005 et quatre classes dans le cas de la segmentation des images de la base CASIA-IrisV4-distance sachant que cette dernière est prise à distance et présente plus d'artefacts en comparaison avec la base ICE-2005.

Nous avons cité dans la section 3.1.2 les principales méthodes utilisées pour estimer les pa-

ramètres. Nous avons retenu la méthode SEM car elle est généralement rapide en comparaison avec les méthodes traditionnelles (34), (88).

La figure 4.2 présente le schéma général de la conception de ces modèles pour la segmentation des images dégradées d'iris. Notre analyse a montré qu'il existe trois facteurs importants qui peuvent influencer le résultat de la segmentation. Le premier est le modèle utilisé à savoir HMC, PMC ou TMC, le deuxième est le type de parcours utilisé pour vectoriser l'image et le troisième est la méthode d'initialisation. De ce fait, nous avons décidé d'étudier l'impact des deux derniers sur chaque modèle afin de répondre aux questions énoncées au début de ce chapitre.

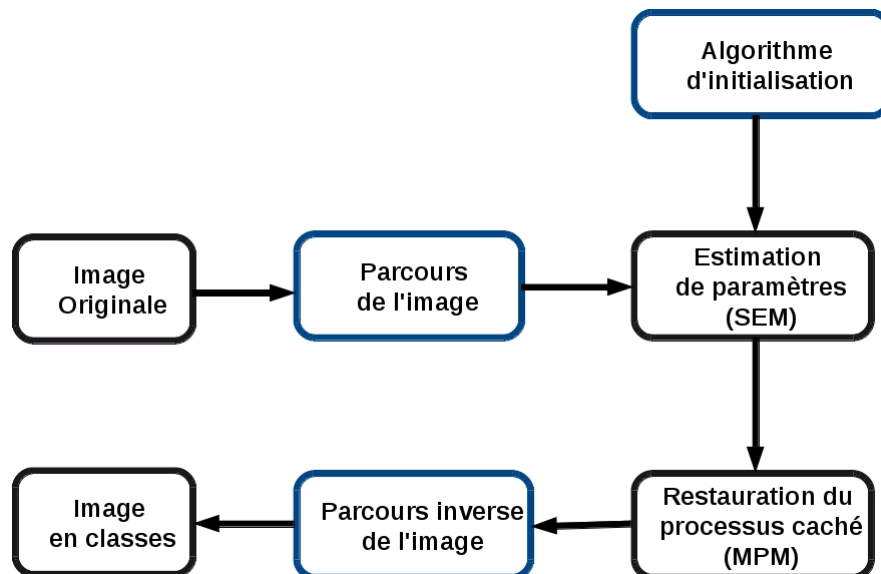


FIGURE 4.2 – Schéma général de la segmentation non supervisée.

Nous précisons que l'objectif initial de cette étude consiste à étudier plusieurs modélisations markoviennes de complexités différentes, de sorte que nous puissions choisir la modélisation la plus appropriée à notre application. Ces modélisations sont le fruit de la volonté d'expérimenter plusieurs combinaisons de différents parcours, de différentes méthodes d'initialisations et de différents modèles Markoviens. Au total, 12 modélisations doivent être testées. Nous avons choisi de tester ces modélisations seulement sur la base de données ICE-2005 et



choisir les meilleures combinaisons résultantes. Ces dernières seront validées sur de grandes bases de données dans les chapitres suivants (Chapitres 5 et 6).

## 4.2 Impact du parcours de l'image sur la segmentation finale

Lors de l'utilisation des chaînes de Markov pour modéliser des images, une transformation de l'image bidimensionnelle en une chaîne monodimensionnelle est obligatoire. Cette transformation doit, autant que possible, préserver les dépendances entre les variables dans l'image. Malheureusement, la transformation la plus simple qui consiste à parcourir l'image ligne par ligne ou colonne par colonne ne satisfait pas la notion de voisinage. Le *parcours Hilbert-Peano* (123) est considéré comme la transformation de référence dans le cas de la segmentation non supervisée par les chaînes de Markov. Ce parcours préserve d'une manière globale la notion de voisinage d'une région étroite dans l'image et assure que la distance, entre deux pixels voisins dans la chaîne, ne dépasse pas un pixel dans l'image, ce qui représente son intérêt principal par rapport à d'autres parcours plus simples.

Pour le cas particulier de la segmentation des images de l'iris, nous avons proposé un nouveau parcours nommé *parcours Escargot*. Il permet de balayer l'image d'une manière plus adaptée à la configuration circulaire de l'iris. Dans la suite de ce chapitre, nous présentons les deux parcours utilisés pour la transformation de l'image en chaîne et leur application sur l'image de l'iris. Enfin, nous montrons l'effet du type de parcours sur la segmentation finale.

### 4.2.1 Parcours Hilbert-Peano

La courbe de *Hilbert-Peano* est une courbe de remplissage de l'espace fractal introduite pour la première fois par David Hilbert en 1891 (67). La construction classique de la courbe de Hilbert n'est possible que pour les images de taille  $2^n * 2^n$ . Ce parcours fractal est brièvement décrit dans la figure 4.3 dans laquelle on considère le cas d'une image de 8 par 8 pixels. Il est obtenu par la reproduction d'un élément de base, dit « générateur » qui est illustré dans la figure 4.3(a). La figure 4.3(b) est une étape intermédiaire qui montre comment le motif initial est reproduit. La figure 4.3(c) montre la courbe finale. Des courbes de *Hilbert-Peano*

généralisées sont également décrites dans la littérature (123).




FIGURE 4.3 – Construction du parcours Hilbert-Peano (3)

#### 4.2.2 Parcours Escargot

L'idée principale du *parcours Escargot* (en anglais *Snail scan*) est de linéariser les pixels de l'image depuis un point centre de coordonnées  $(x_0, y_0)$  (141). La conception de ce parcours est basée sur l'algorithme de tracé d'Andres (54). Ce dernier associe à un pixel de coordonnées  $(x, y)$  un cercle centré en  $(x_0, y_0)$  suivant l'équation :

$$\left(r - \frac{1}{2}\right)^2 < (x - x_0)^2 + (y - y_0)^2 < \left(r + \frac{1}{2}\right)^2 \quad (4.1)$$

Dans un premier temps, nous divisons l'image en 8 régions comme illustré la Figure 4.4(a). Chaque région est un "octant". Pour un rayon  $r$  donné, nous se plaçons dans l'un des octants de l'image. Pour tout point de coordonnées  $(x, y)$ , nous choisissons exclusivement un parmi ces voisins de coordonnées  $(x + 1, y)$ ,  $(x, y - 1)$  et  $(x + 1, y - 1)$  qui vérifie l'équation 4.1. De manière itérative, nous appliquons sur tous les points de distance  $r$  et appartenant au premier octant traité, la même procédure. Les points des autres octants s'obtiennent par symétrie comme illustré sur la figure 4.4(a). Ces points qui appartiennent au cercle d'Andres de rayon  $r$  (Figure 4.4(b)) vont donner une chaîne correspondant au rayon  $r$  comme il est illustré dans la Figure 4.4(c).

Dans un second temps, les différentes chaînes correspondant aux différents rayons sont reliées pour construire un escargot (Figure 4.4(d)) qui implique l'extraction d'une partie de l'image qui sera considérée comme l'observation complète. D'un point de vue statistique, il pourrait apparaître comme un inconvénient que le *parcours d'Escargot* ne prenne pas en compte une partie de l'image. En fait, puisque nous isolons la partie informative de l'image, le *parcours Escargot* contribue à diminuer la variance d'échantillonnage, ce qui est un réel avantage lorsque nous utilisons des méthodes de segmentation non supervisées statistiques. De plus, il diminue la taille de l'échantillon à traiter ce qui peut être considéré comme un point très important lors de l'utilisation de ces modèles dans des applications en temps réel.




FIGURE 4.4 – Construction du *parcours Escargot*. Illustration des pixels choisis par l'algorithme du tracé d'Andres dans chaque octant pour un rayon égal à 2 (a). L'ensemble des pixels choisis par l'algorithme du tracé d'Andres pour un rayon égal à 2 (b). Chaîne extraite pour un rayon égal à 2 (c). Chaîne complète extraite par le *parcours Escargot*(d).

### 4.2.3 Application sur l'image de l'iris

La topographie des différentes régions d'une image de l'iris est très bien définie et stable. Il est bien connu que la pupille est à l'intérieur de l'iris. Ce dernier est entouré par la sclera et les paupières. Pour cette raison, nous pensons que le *parcours Escargot* est très bien adapté pour balayer des images de l'iris.

La Figure 4.5 montre le résultats de la transformation d'une image de l'iris segmentée en quatre régions par les deux parcours. Le point représenté par une étoile jaune dans les Figures 4.5(a) et 4.5(b) est le premier point dans la chaîne extraite. Dans le cas du *parcours d'Escargot*, le point du départ correspond au centre de la pupille détecté dans la Section 4.1.1.

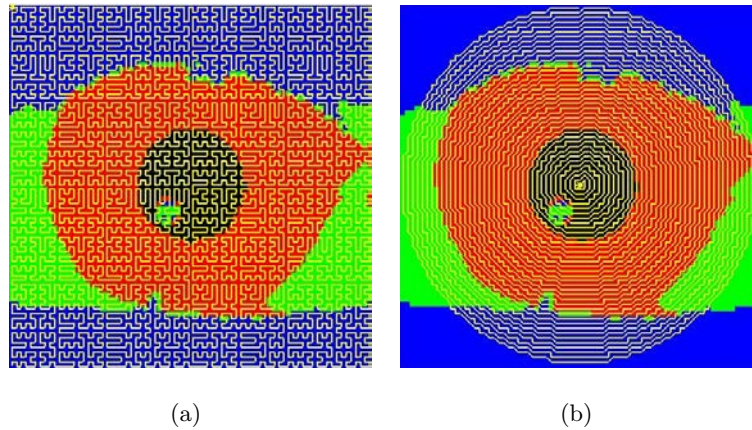



FIGURE 4.5 – Exemple de transformation d'une image de l'iris segmentée en régions en une chaîne. *Parcours Hilbert-Peano* (a). *Parcours Escargot* (b).


Pour toute transformation 2D en un signal 1D, la conservation du voisinage est considérée comme un critère important. Cette conservation permet de faire correspondre les points proches dans l'espace 2D aux points proches dans l'espace 1D. Nous considérons dans ce travail, le voisinage comme une proximité spatiale locale permettant d'associer les pixels similaires appartenant à la même classe comme des voisins dans la chaîne.

La figure 4.6(a) montre que la notion de voisinage en terme d'appartenance à la même classe est moins bien conservée lors de l'utilisation du *parcours Hilbert-Peano* par rapport au

*parcours d'Escargot* (Figure 4.6(b)). Ce dernier permet de préserver la notion de voisinage à l'intérieur de la même classe. En plus, il permet de diminuer largement le nombre de transitions entre les différentes classes. Si nous prenons par exemple la classe iris (avec une couleur rouge dans les chaînes), nous voyons clairement que cette région se trouve dans plusieurs endroits dans la chaîne extraite par un *parcours Hilbert-Peano* et elle est bien concentrée au milieu de la chaîne lors de l'utilisation du *parcours d'Escargot* (Figure 4.6(b)).



(a)



(b)

FIGURE 4.6 – La transition de la chaîne extraite. *Parcours Hilbert-Peano* (a). *Parcours Es-cargot* (b).

#### 4.2.4 Comparaison des segmentations

Les expériences réalisées dans cette partie consistent à tester différents parcours (Hilbert-Peano et escargot) avec différents modèles de Chaînes de Markov (HMC, PMC et TMC). Pour neutraliser l'effet de l'initialisation sur le résultat final de la segmentation, nous avons choisi d'utiliser l'algorithme Kmeans pour initialiser tous les modèles (Sous-section 4.3.1). Le but de ces expériences est d'évaluer l'impact du parcours sur la segmentation.

Pour simplifier la notation, nous utiliserons la première lettre de la méthode de l'initialisation et le type du parcours pour noter chaque modélisation. Par exemple la notation HMC\_SK exprime l'utilisation du modèle HMC avec le *parcours Escargot* (S pour Snail) et une initialisation par l'algorithme Kmeans. Nous utiliserons la même notation pour toutes les modélisations testées dans ce chapitre.

Les Figures 4.7, 4.8 et 4.9 présentent des exemples d'images originales et leurs segmentations respectives selon les différentes modélisations. Les images de l'iris sélectionnées sont de mauvaise qualité et difficiles à segmenter. À titre d'exemple, l'image de la première ligne est prise avec un faible éclairage mais régulier, par conséquent elle souffre de faible contraste, la deuxième, la troisième et la cinquième sont prises avec un éclairage irrégulier donc la répartition d'illumination est hétérogène sur l'image. La quatrième englobe plusieurs artefacts tels que une forte variation d'illumination, un faible contraste iris/sclera et une occlusion par les paupières et les cils. Notre évaluation qualitative est visuelle, basée sur le fait que la région de l'iris est bien séparée de la pupille et de la sclera ou non. Nous avons constaté que les segmentations finales par les modélisations basées sur le *parcours Escargot* préservent ou améliorent les résultats en comparaison avec les modélisations basées sur le *parcours Hilbert-Peano*. D'autre part, l'utilisation du *parcours Escargot* permet d'avoir des contours de l'iris plus réguliers qui facilitent la modélisation de ces contours par des contours paramétrés.

Globalement, nous constatons que l'utilisation de la modélisation HMC\_SK donne des résultats nettement meilleurs que ceux fournis par la modélisation PMC\_SK. Ceci est dû au fait que le modèle PMC\_SK a tendance à fusionner des pixels non iris à la classe iris, ce qui peut être désavantageux pour la recherche des contours paramétrés.




FIGURE 4.7 – Segmentation d’images dégradées de l’iris (ICE-2005) par les modélisations basées sur le modèle HMC. De gauche à droite : image originale, initialisation par Kmeans, HMC\_PK, HMC\_SK. De haut en bas : Image 245102.pgm, Image 240016.pgm, Image 242025.pgm, Image 247124.pgm, Image 222305.pgm






FIGURE 4.8 – Segmentation d’images dégradées de l’iris (ICE-2005) par les modélisations basées sur le modèle PMC. De gauche à droite : image originale, initialisation par Kmeans, PMC\_PK, PMC\_SK. De haut en bas : Image 245102.pgm, Image 240016.pgm, Image 242025.pgm, Image 247124.pgm, Image 222305.pgm




FIGURE 4.9 – Segmentation d’images dégradées de l’iris (ICE-2005) par les modélisations basées sur le modèle TMC. De gauche à droite : image originale, initialisation par Kmeans, TMC\_PK, TMC\_SK. De haut en bas : Image 245102.pgm, Image 240016.pgm, Image 242025.pgm, Image 247124.pgm, Image 222305.pgm




FIGURE 4.10 – Segmentation d’images dégradées de l’iris (ICE-2005) par les modélisations basées sur les modèles TMC et TMC-SOP (Triplet Markov Chain with One Stationarity of Pupil noise). De gauche à droite : TMC\_PK, TMC-OSP\_PK, TMC\_PK, TMC-OSP\_PK , segmentation par TMC. De haut en bas : Image 245102.pgm, Image 240016.pgm, Image 242025.pgm, Image 247124.pgm, Image 222305.pgm

Notre analyse qualitative, montre qu'il n'y a pas une différence significative entre les segmentations produites par les modélisations TMC\_PK et TMC\_SK. Nous avons remarqué une tendance à fusionner des pixels de la région de l'iris avec la région de la pupille. Nous avons considéré jusqu'à maintenant un modèle TMC avec deux de classes pour le processus auxillaire qui modélise la variation d'illumination. Cependant, nous avons noté que la variation de l'éclairage n'affecte pas l'illumination de la région de la pupille. Pour cette raison, nous avons supposé que le bruit de la classe pupille est stationnaire. Nous avons proposé de modéliser le processus auxiliaire de la région pupille par une seule classe contrairement aux autres classes recherchées pour lesquelles nous gardons deux de classes. Cette configuration nommée TMC-OSP (Triplet Markov Chain with One Stationarity of Pupil noise), permet d'améliorer la qualité de la segmentation de la région pupille en comparaison avec la configuration initiale (même nombre de classes du processus auxiliaire). La figure 4.10 montre la segmentation des images précédentes par les modélisations basées sur le modèle TMC-OSP.

En résumant cette étude qualitative, nous constatons deux points importants :

- *Le parcours Escargot* préserve ou améliore le résultat de la segmentation par rapport au *Parcours Hilbert-Peano*.
- Les modèles HMC\_SK et TMC-OSP\_SK ont tendance à améliorer les résultats par rapport à l'initialisation, contrairement au modèle PMC\_SK qui préserve, voire dégrade, les segmentations initiales.

#### 4.2.5 Évaluation des cercles de normalisation

L'analyse qualitative décrite auparavant a montré que la méthode de transformation de l'image en chaîne influence les résultats de la segmentation. Pour montrer et confirmer ceci, nous proposons d'effectuer une évaluation quantitative.

En raison d'absence de vérité terrain pour la plupart des bases de données publiques, l'évaluation quantitative des résultats de la segmentation des images de l'iris est considérée comme une tâche difficile. Pour cette raison, nous avons limité notre étude aux cercles de normalisation. Tout d'abord, une segmentation manuelle des images de la base ICE-2005 a

été effectuée par notre équipe (125) pour déterminer les paramètres circulaires des contours de l'iris. Ces paramètres manuels sont utilisés comme une vérité terrain comme dans les travaux (125) et (13).

Notre objectif est de rechercher les contours de l'iris sur l'image segmentée par l'un des modèles statistiques cités auparavant. Nous pensons que les modèles qui utilisent le *parcours Escargot* affineront les contours recherchés par rapport à ceux qui utilisent le *parcours Peano* et par conséquent, ils permettront une détection plus précise des cercles de normalisation. Les paramètres circulaires qui modélisent les contours de l'iris sont calculés en utilisant le module de segmentation d'OSIRIS-V4 (Section 5.2.4) appliqué à l'image des régions.

Pour évaluer la précision des cercles de normalisation, nous avons calculé l'erreur de segmentation ( $E$ ) employée dans la compétition NICE.I (91) sur chaque image. L'erreur de segmentation ( $E$ ) est donnée par l'équation suivante :

$$E = \frac{1}{l \times c} \sum_{i=1}^l \sum_{j=1}^c \mathcal{G}(i, j) \otimes \mathcal{S}(i, j) \quad (4.2)$$

où  $l, c$  notent respectivement le nombre de lignes et de colonnes de l'image.  $\mathcal{G}$  représente la région définie par les deux cercles de la vérité terrain et  $\mathcal{S}$  représente la région définie par les deux cercles calculés sur l'image segmentée par Kmeans ou par les modèles markoviens testés dans cette partie. L'opérateur XOR «  $\otimes$  » est utilisé pour évaluer les pixels différents entre  $\mathcal{G}$  et  $\mathcal{S}$ .

Les Figures 4.11(a), 4.11(c), 4.11(e) représentent les erreurs de segmentation calculées sur chaque image de la base ICE-2005. Nous remarquons qu'une grande partie des images (90%) ont presque les mêmes erreurs quel que soit le parcours utilisé. Sachant que la production de la vérité terrain est subjective relativement aux annotateurs, qui peuvent donner des vérités terrains différentes, nous pouvons considérer qu'il n'y a pas une différence significative sur cette portion d'images. Cependant, la vraie différence entre les modèles est visible sur les 10% des images de la base ICE-2005 où l'erreur est importante comme cela est illustré dans les Figures 4.11(b), 4.11(d), 4.11(f). De plus, nous reportons dans les Tableaux 4.1, 4.2, 4.3 l'erreur de segmentation moyenne donnée par l'Équation 4.3 et exprimée en pourcentage. L'erreur moyenne sur toute la base de données ICE-2005 est notée  $\bar{E}$ , et celle calculée sur les

10% des images de la base de données avec les erreurs les plus élevées est notée  $\overline{E}_{10}$ .

$$\overline{E} = \left( \frac{1}{N} \sum_{i=1}^N E_i \right) \times 100 \quad (4.3)$$

Ces résultats expérimentaux montrent qu'une diminution des erreurs de segmentation moyennes  $\overline{E}$  et  $\overline{E}_{10}$  est respectivement remarquée lors de l'utilisation de HMC\_SK, PMC\_SK et TMC-OSP\_SK en comparaison avec HMC\_PK, PMC\_PK et TMC-OSP\_PK, soit une amélioration de 6.28%, 11.39%, 2.58% de l'erreur  $\overline{E}$  et de 24.55%, 24.20%, 0.70% de l'erreur  $\overline{E}_{10}$  sur la base ICE-2005. Ces résultats confirment que *le parcours d'Escargot* proposé améliore la précision des cercles de normalisation en général et surtout celle des images avec des erreurs élevées quel que soit le modèle utilisé pour la segmentation.

Il faut noter que le modèle TMC-SOP\_SK diminue largement l'erreur  $\overline{E}_{10}$  par rapport aux modèles HMC\_SK et PMC\_SK. Le succès de ce modèle peut être expliquée par le fait qu'il est plus général et donc il peut modéliser la richesse des images de l'iris. De plus, il permet de modéliser la non stationnarité du bruit, exprimée par exemple par une variation d'illumination dans les images de la base ICE-2005, contrairement aux modèles HMC\_SK et PMC\_SK où le bruit est considéré stationnaire.

Pour compléter cette étude, nous comparons les erreurs de segmentation moyennes des modèles proposés avec l'erreur de segmentation moyenne produite par la segmentation Kmeans (utilisée pour initialiser les modèles markoviens), considérée comme une référence, afin d'étudier l'apport des modèles markoviens. Les modélisations basées sur le modèle HMC et le modèle TMC-OSP diminuent les erreurs de segmentation moyennes  $\overline{E}$  et  $\overline{E}_{10}$ , quel que soit le parcours utilisé, et par conséquent donnent une bonne localisation des cercles de normalisation. En revanche, les modélisations basées sur le modèle PMC ont tendance à dégrader la précision des cercles (augmentation des erreurs de segmentation moyennes) par rapport à la référence.

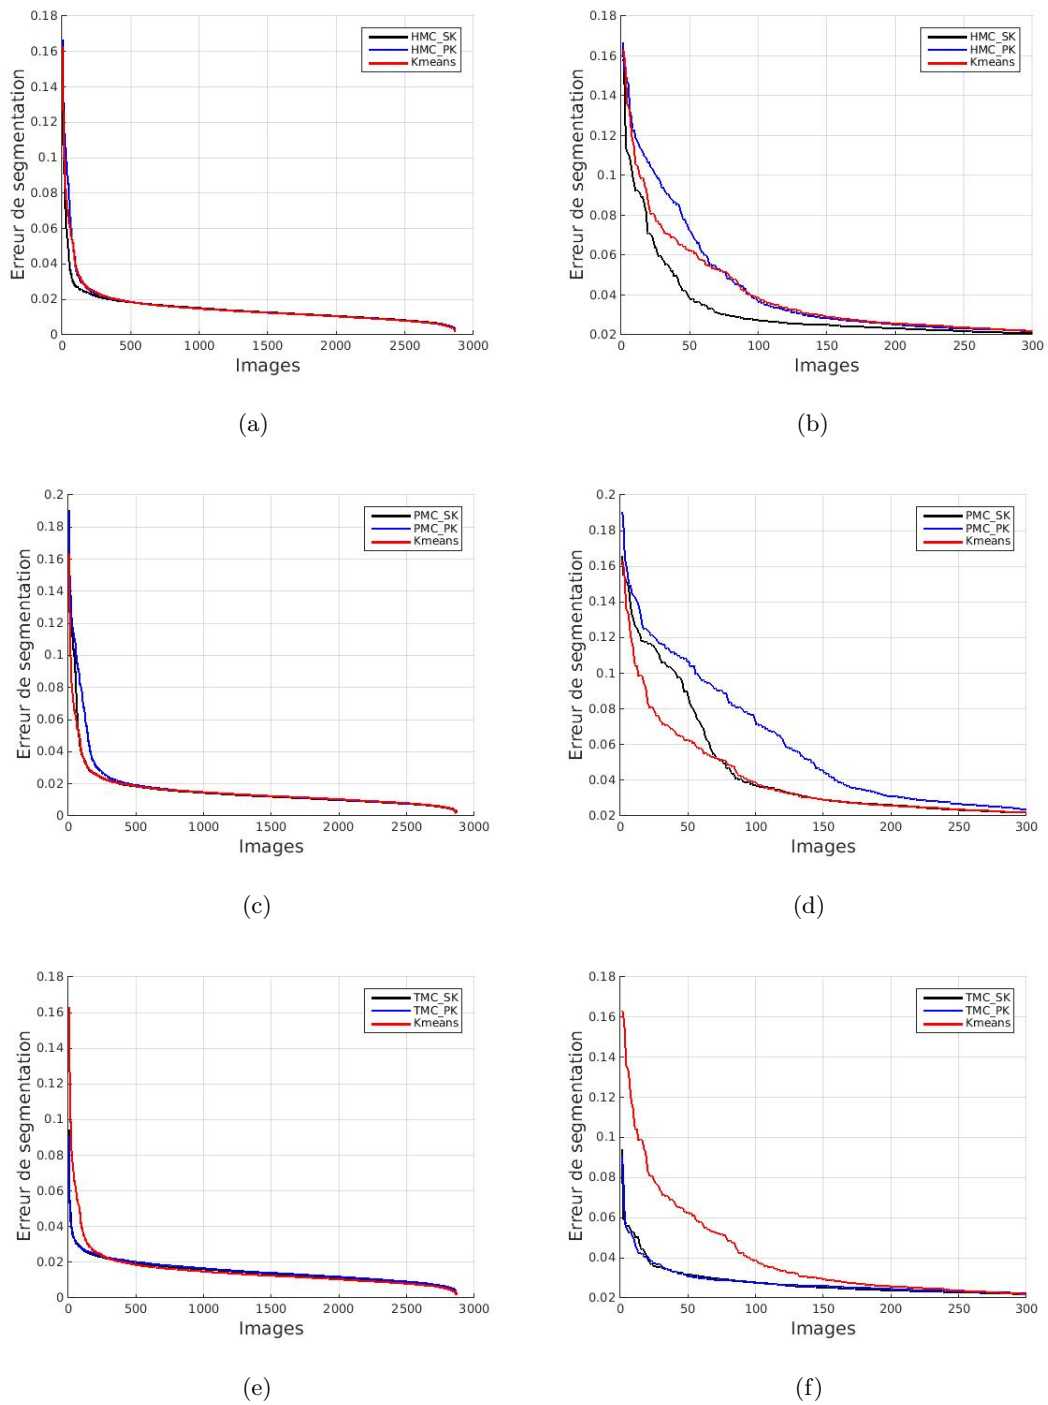


FIGURE 4.11 – Les erreurs de segmentation  $E$  produites par les différentes modélisations. Erreurs de segmentation  $E$  sur toute la base de données ICE-2005 (a, c, e). Sur 10% des images de la base ICE-2005 avec des erreurs de segmentation  $E$  les plus élevées (b, d, f).

TABLE 4.1: Erreurs de segmentation moyennes produites par kmeans et les modèles HMC\_PK et HMC\_SK .

	<b>Kmeans</b>	<b>HMC_PK</b>	<b>HMC_SK</b>
$\overline{E}$ (%)	1.56	1.59	<b>1.49</b>
$\overline{E}_{10}$ (%)	4.20	4.44	<b>3.35</b>

TABLE 4.2: Erreurs de segmentation moyennes produites par kmeans et les modèles PMC\_PK et PMC\_SK.

	<b>Kmeans</b>	<b>PMC_PK</b>	<b>PMC_SK</b>
$\overline{E}$ (%)	<b>1.56</b>	1.76	1.58
$\overline{E}_{10}$ (%)	<b>4.20</b>	6.24	4.73

TABLE 4.3: Erreurs de segmentation moyennes produites par kmeans et les modèles TMC\_PK et TMC\_SK.

	<b>Kmeans</b>	<b>TMC-OSP_PK</b>	<b>TMC-OSP_SK</b>
$\overline{E}$ (%)	1.56	1.55	<b>1.51</b>
$\overline{E}_{10}$ (%)	4.20	2.85	<b>2.83</b>

Dans cette partie, nous avons montré que le *parcours Escargot* est le meilleur parcours pour la transformation des images de l'iris. Pour cette raison, ce parcours est exploité dans la suite du travail.

### 4.3 Impact des Méthodes d'initialisation sur la segmentation finale

Comme il a été mentionné auparavant, une bonne initialisation de l'ensemble des paramètres  $\theta^{(0)}$  est un point crucial pour le bon fonctionnement de la méthode d'estimation des



paramètres (SEM) utilisée dans ce travail.

Une partie décisive dans notre travail est de rechercher la meilleure méthode dédiée pour optimiser l'initialisation des paramètres dans un cas aussi spécifique que celui considéré dans ce travail. Nous avons exploré quelques méthodes de segmentation en régions existantes dans le but d'avoir des données complètes  $(\mathbf{x}^{(0)}, \mathbf{y})$ . L'initialisation de l'ensemble des paramètres se fait à partir de ces données complètes.

### 4.3.1 Initialisation par K-means

Dans ce travail, nous avons utilisé l'algorithme Kmeans (81) pour segmenter l'image de l'iris en  $K$  classes dans le but d'estimer l'ensemble des paramètres initiaux  $\theta^{(0)}$  à partir des données complétées  $(\mathbf{x}^{(0)}, \mathbf{y})$ . Cet algorithme se base sur la distance euclidienne entre le niveau du gris d'un pixel et les centres de classes pour regrouper les pixels de l'iris. Ces distances sont mises à jour d'une manière itérative jusqu'à ce que les centres de classes se stabilisent.

### 4.3.2 Initialisation par Histogramme

Nous introduisons une nouvelle méthode de regroupement inspirée par le travail (39) pour initialiser les paramètres. Cette méthode est basée sur la recherche des pics dominants de l'histogramme de l'image. Ce dernier représente la distribution des intensités de l'image, donc il produit une description générale de l'image. Si l'image contient plusieurs classes, l'histogramme est caractérisé par plusieurs pics, donc, on peut associer à chaque pic une région. Dans la suite de cette section, nous décrirons l'algorithme de regroupement par histogramme qui se compose de trois étapes. Nous supposons que  $H(x)$ , où  $0 \leq H(x) \leq 1$  et  $0 \leq x \leq 255$ , présente l'histogramme normalisé de l'image.

- **Détection de pics**

Premièrement, il est nécessaire d'ajouter  $H(-1) = H(256) = 0$  pour la détection des pics qui sont présents entre 0 et 255. Nous recherchons l'ensemble  $P_0$  de tous les pics locaux suivant l'équation :

$$P_0 = \{(x, H(x)), H(x-1) \leq H(x) \cap H(x) \geq H(x+1)\} \quad (4.4)$$

Deuxièmement, nous considérons tous les pics locaux  $P_0$  comme les points d'une nouvelle courbe. Nous recherchons les pics significatifs  $P_1$  sur cette nouvelle courbe.

$$P_1 = \{(x_0, H(x_0)), H(x_0 - 1) \leq H(x_0) \cap H(x_0) \geq H(x_0 + 1)\} \quad (4.5)$$

Troisièmement, tous les pics plus petits qu'un seuil  $S_0$  sont supprimés. Ce seuil est proportionnel à la valeur moyenne des pics  $H_{avg}$  sans prendre en compte le pic maximal  $H_{max}$ . Nous notons le pic le plus petit par  $H_{min}$ .

$$S_0 = H_{min} + (0.2 * H_{avg}). \quad (4.6)$$

Finalement, tous les pics les plus proches sont supprimés. Nous définissons le seuil  $S_1$  :

$$S_1 = \frac{(\sum_{\delta_0 \in \Delta} (\delta_0)) - \delta_{max}}{Card(\Delta)}, \text{ avec} \quad (4.7)$$

$$\Delta = \{\delta_i = (x_{i+1} - x_i), 0 \leq i \leq N\},$$

$$\delta_{max} = \max_{\delta_i \in \Delta} (\delta_i)$$

Cette dernière étape est répétée jusqu'à que le cardinal de  $\Delta$  est égal au nombre de classes recherchées. L'ensemble final des pics est  $P = \{(x_{0i}, H(x_{0i})), 1 \leq i \leq K\}$ .

#### • Détection des vallées

Dans notre cas, nous souhaitons détecter  $K$  pics, par conséquent  $K - 1$  vallées doivent être détectées. Chaque vallée est comprise entre deux pics consécutifs. Nous considérons que chaque classe  $\omega_i$  est représentée par une distribution normale  $\mathcal{N}(\mu_i, \sigma_i)$  où  $\mu_i = x_{0i}$ . La densité de probabilité des classes est représentée par un mélange gaussien exprimé par l'équation 4.8. Dans notre cas, nous avons  $2K$  paramètres à estimer. Chaque classe est représentée par la probabilité de la classe  $\pi_i$  et l'écart-type  $\sigma_i$ .

$$f(x, \pi, \sigma) = \sum_i^K f_i(x, \pi, \sigma), \text{ avec} \quad (4.8)$$

$$f_i(x, \pi_i, \sigma_i) = \frac{\pi_i}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{x - \mu_i}{\sigma_i}\right)^2\right).$$

Une fonction objectif qui exprime la dissimilarité entre l'histogramme original et le mélange gaussien est défini comme suit :

$$F(x, \pi, \sigma) = \sum_{x=\mu_i}^{\mu_K} (f(x, \pi, \sigma) - H(x))^2. \quad (4.9)$$

Notre objectif est d'estimer les paramètres qui minimisent l'équation (4.9). L'estimation de ces paramètres rend le modèle du mélange gaussien bien défini. Dans ce cas, la détermination des vallées est possible selon l'équation 4.10. Cette dernière permet de minimiser la probabilité de l'erreur de classification de la classe  $\omega_i$ .

$$V_{0i} = \underset{0 \leq x \leq 255}{\operatorname{argmin}} (|f_{i+1}(x) - f_i(x)|), 1 \leq i \leq (K - 1). \quad (4.10)$$

Il est nécessaire d'ajouter les deux vallées  $V_{00} = -1, V_{0K} = 256$  pour limiter chaque pic entre deux vallées.

- **Seuillage :**

La dernière étape de cette méthode consiste à appliquer les valeurs des vallées détectées comme des seuils pour séparer les différentes régions.

$$H(x) \in \omega_i \text{ si } V_{0(i-1)} \leq H(x) \leq V_{0i}. \quad (4.11)$$

### 4.3.3 Évaluation des cercles de normalisation

Dans cette partie, nous avons choisi de considérer quelques exemples d'images dégradées de l'iris qui sont difficiles à segmenter par l'algorithme Kmeans, celui-ci produit une mauvaise initialisation. Nous représentons les images originales et leurs segmentations respectives selon les différentes modélisations dans les Figures 4.12, 4.13 et 4.14. Toutes ces images sont prises avec un éclairage irrégulier produisant une variation importante de la répartition de l'illumination. Les images de la première et deuxième ligne présentent des paupières saturées en illumination ce qui se traduit par une fusion des deux régions les plus sombres pupille et iris lors de l'utilisation de l'algorithme Kmeans. Les trois dernières présentent une répartition d'illumination distincte entre la partie gauche et la partie droite de l'image.

Globalement, nous constatons que l'utilisation des modélisations HMC\_SH et PMC\_SH donnent des résultats nettement meilleurs que ceux fournis par les modélisations HMC\_SK et PMC\_SK. Cependant, la modélisation TMC-SOP\_SH a tendance à dégrader les contours iris/sclera comme illustré dans les deux premières lignes de la figure 4.14.

Afin d'évaluer quantitativement l'impact de la méthode d'initialisation sur la segmentation des images dégradées de l'iris, nous avons adopté les deux erreurs de segmentation moyennes  $\overline{E}$  et  $\overline{E}_{10}$ . Nous rappelons que l'erreur de segmentation moyenne est exprimée par l'Équation 4.3.  $\overline{E}$  représente l'erreur moyenne calculée sur toute la base ICE-2005 et  $\overline{E}_{10}$  représente l'erreur moyenne des 10% des images avec les erreurs les plus élevées.

La première remarque que nous pouvons faire en observant les résultats présentés dans la première colonne du Tableau 4.4 en comparaison avec ceux présentés dans la première colonne du Tableau 4.1 est que la méthode d'initialisation d'Histogramme est meilleure que l'algorithme Kmeans. Elle permet une diminution des erreurs moyennes  $\overline{E}$  et  $\overline{E}_{10}$ , soit une amélioration de 4.49% et 11.90%.

Les résultats présentés dans les Tableaux 4.4, 4.5, 4.6 montrent que le modèle HMC\_SH améliore la segmentation par rapport au modèle HMC\_SK, soit une amélioration de 4.93% et 18.21% de l'erreur  $\overline{E}$  et de l'erreur  $\overline{E}_{10}$ . Le modèle PMC\_SH préserve l'erreur moyenne  $\overline{E}$  avec une amélioration significative de l'erreur  $\overline{E}_{10}$  (6.21%). Cependant, la modélisation TMC-OSP\_SH dégrade la précision de la segmentation en comparaison avec TMC-OSP\_SK.




FIGURE 4.12 – Comparaison des segmentations d’images dégradées de l’iris (ICE-2005) par les modèles HMC\_SK et HMC\_SH. De gauche à droite : image originale, initialisation par Kmeans, HMC\_SK, initialisation par Histogramme, PMC\_SH. De haut en bas : Image 239501.pgm, Image 240163.pgm, Image 241186.pgm, Image 241672.pgm, Image 242216.pgm




FIGURE 4.13 – Comparaison des segmentations d’images dégradées de l’iris (ICE-2005) par les modèles PMC\_SK et PMC\_SH. De gauche à droite : image originale, initialisation par Kmeans, PMC\_SK, initialisation par Histogramme, PMC\_SH. De haut en bas : Image 239501.pgm, Image 240163.pgm, Image 241186.pgm, Image 241672.pgm, Image 242216.pgm




FIGURE 4.14 – Comparaison des segmentations d’images dégradées de l’iris (ICE-2005) par les modèles TMC-OSP\_SK et TMS-OSP\_SH. De gauche à droite : image originale, initialisation par Kmeans, TMS-OSP\_SK, initialisation par Histogramme, TMS-OSP\_SH. De haut en bas : Image 239501.pgm, Image 240163.pgm, Image 241186.pgm, Image 241672.pgm, Image 242216.pgm

La comparaison des erreurs  $\overline{E}$  produites par les modèles HMC\_SH, PMC\_SH, TMC-OSP\_SH et celle de l'initialisation d'Histogramme (considérée comme une référence) permet de montrer que seul le modèle HMC\_SH améliore la segmentation par rapport à la référence.

TABLE 4.4: Erreurs de segmentation moyennes produites par l'initialisation Histogramme et les modèles HMC\_SH et HMC\_SK.

	<b>Initialisation Histogramme</b>	<b>HMC_SH</b>	<b>HMC_SK</b>
$\overline{E}$ (%)	1.49	<b>1.42</b>	1.49
$\overline{E}_{10}$ (%)	3.70	<b>2.74</b>	3.35

TABLE 4.5: Erreurs de segmentation moyennes produites par l'initialisation Histogramme et les modèles PMC\_SH et PMC\_SK.

	<b>Initialisation Histogramme</b>	<b>PMC_SH</b>	<b>PMC_SK</b>
$\overline{E}$ (%)	<b>1.49</b>	1.58	1.58
$\overline{E}_{10}$ (%)	<b>3.70</b>	4.39	4.73

TABLE 4.6: Erreurs de segmentation moyennes produites par l'initialisation Histogramme et les modèles TMC\_SH et TMC\_SK.

	<b>Initialisation Histogramme</b>	<b>TMC-OSP_SH</b>	<b>TMC-OSP_SK</b>
$\overline{E}$ (%)	<b>1.49</b>	1.55	1.51
$\overline{E}_{10}$ (%)	3.70	2.99	<b>2.83</b>

En résumant cette étude, nous constatons les points suivants :

- Une bonne initialisation est nécessaire pour le bon fonctionnement des modélisations basées sur le modèle HMC, contrairement aux modélisations basées sur le TMC-OSP.



- Les modélisations basées sur le modèle PMC ont tendance à dégrader les performances de segmentation par rapport à l'initialisation. Ceci peut être expliqué soit par le fait que ces modélisations ne sont pas adaptées aux données, soit par l'hypothèse selon laquelle le bruit suit une loi normale n'est pas vraie.
- La meilleure modélisation en terme de diminution des deux erreurs de segmentation moyennes est la HMC\_SH qui est basée sur le modèle simple HMC. Elle dépasse toutes les modélisations basées sur le modèle complexe TMC-OSP.

## 4.4 Conclusion

Dans ce chapitre, nous avons proposé plusieurs modélisations pour une segmentation non supervisée des images de l'iris, que nous avons testées sur la base ICE-2005. Nous avons étudié l'impact de la façon de transformer l'image 2D en un signal 1D ainsi que celui de la méthode d'initialisation sur les résultats de la segmentation des images dégradées de l'iris. Pour évaluer les différentes modélisations, nous nous sommes basés sur l'erreur de segmentation utilisée dans la compétition NICE-I. Dans un premier temps, nous avons montré que le parcours proposé dans le cadre de cette thèse nommé *parcours Escargot*, qui permet de faire une linéarisation de l'image, influence positivement sur les résultats de la segmentation par rapport à ceux trouvés lors de l'utilisation du *parcours Hilbert-Peano*, avec une amélioration de 6.28%, 11.39%, 2.58% de l'erreur  $\bar{E}$  et de 24.55%, 24.20%, 0.70% de l'erreur  $\bar{E}_{10}$ , respectivement par les modèles HMC\_SK, PMC\_SK, TMC-OSP\_SK. Nos résultats expérimentaux montrent également que l'utilisation du modèle simple HMC avec une bonne initialisation dépasse toutes les modélisations basées sur le modèle complexe TMC-SOP en terme d'erreur de segmentation moyenne. La segmentation par le modèle PMC testée dans ce travail, bien qu'en general plus performante dans certaines applications que l'utilisation des HMC, semble ici ne pas remédier au problème de segmentation des images dégradées de l'iris. Le PMC testé a une tendance à dégrader les performances par rapport à l'état initial.

Dans le chapitre suivant, nous présenterons la mise en œuvre d'un système de reconnaissance de l'iris basé sur des modélisations Markoviennes (le modèle HMC et TMS-SOP). Ce

Le système sera testé sur de grandes bases de données à savoir ICE-2005, CASIA-IrisV4-distance afin de réaliser une comparaison avec l'état de l'art.

## Chapitre 5

# Mise en œuvre des chaînes de Markov pour la reconnaissance d’iris

---

<b>5.1</b>	<b>Introduction</b>	<b>121</b>
<b>5.2</b>	<b>Estimation de contours et module de reconnaissance</b>	<b>122</b>
5.2.1	Localisation automatique de la pupille	122
5.2.2	Paramétrisation des contours	125
5.2.3	Construction du masque de l’iris	126
5.2.4	Modules de reconnaissance	128
<b>5.3</b>	<b>Évaluation des Chaînes de Markov pour la reconnaissance de l’iris</b>	<b>128</b>
5.3.1	Limitation de la méthode d’initialisation par histogramme	128
5.3.2	Évaluation des performances	131
5.3.3	Évaluation des temps de calcul	135
<b>5.4</b>	<b>Impact du sous échantillonnage sur les performances et les temps de calculs</b>	<b>136</b>
5.4.1	Sous-échantillonnage de l’image	136
5.4.2	Sous-échantillonnage de la chaîne	138
<b>5.5</b>	<b>Conclusion</b>	<b>140</b>

---

## 5.1 Introduction

LE but ultime de la mise en œuvre d'algorithmes de segmentation non supervisée des images dégradées de l'iris est de concevoir un système de reconnaissance efficace. Plus précisément, notre objectif est de montrer que l'utilisation d'algorithmes de segmentations non supervisées basées sur des techniques markoviennes permet d'améliorer la précision de la détection des cercles qui modélisent les contours de l'iris (contours iris/pupille et iris/sclera). Nous savons, d'après la littérature, que cet élément est fondamental pour la qualité des mesures de performance résultantes. Dans ce chapitre, nous détaillons les différents modules qui constituent ce nouveau système de reconnaissance de l'iris. Son organigramme est présenté dans la figure 5.1.

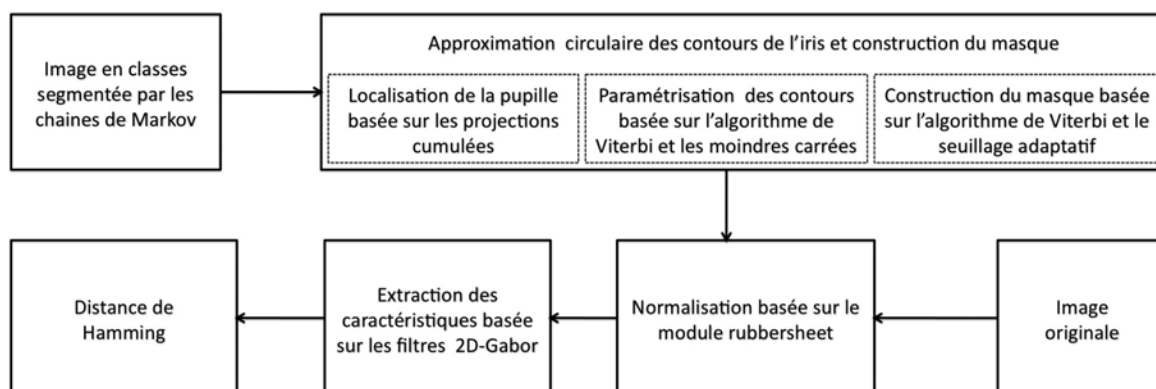


FIGURE 5.1 – Organigramme du système proposé pour la reconnaissance de l'iris

Le système prend comme entrée une image de l'iris en quatre régions obtenue par une segmentation non supervisée par les meilleurs modèles choisis dans le chapitre précédent. Puis, une étape d'estimation des contours de l'iris est réalisée. Cette dernière utilise l'algorithme de Viterbi pour trouver les contours de l'iris et la méthode des moindres carrés pour les modéliser sous forme de cercles (Section 5.2.2). Ces contours sont reportés sur l'image originale par la suite. Ensuite, une étape de construction du masque de l'iris est réalisée par application de l'algorithme de Viterbi ainsi qu'un seuillage adaptatif. Enfin, les modules génériques d'OSIRIS-V4 (normalisation, extraction des caractéristiques, comparaison) sont utilisés pour

effectuer l'appariement entre deux motifs.

## 5.2 Estimation de contours et module de reconnaissance

La segmentation non supervisée de l'iris basée sur les chaînes de Markov consiste à estimer la réalisation non observée  $x$  qui décrit les 4 classes (iris, sclera, pupille, peau) à partir de la réalisation observée  $y$  qui correspond à l'intensité des pixels de l'image en niveau de gris. Cette segmentation produit une image en classes qui sera traitée par une étape de post-segmentation. Cette dernière repose sur une approche de contour pour trouver une description paramétrique des contours de l'iris et produire un masque de l'iris. A cette fin, nous proposons d'utiliser le module de segmentation du système de référence OSIRIS-V4 développé par notre équipe. Ce dernier comporte trois étapes : localisation automatique de la pupille, paramétrisation des contours, construction du masque de l'iris. Nous décrivons brièvement ces trois étapes et nous spécifions les modifications réalisées pour que ce module fonctionne mieux sur des images de classes.

### 5.2.1 Localisation automatique de la pupille

Le système OSIRIS-V4 est conçu pour la segmentation des images de l'iris en niveaux de gris. L'algorithme proposé pour la segmentation de l'iris est initialisé par le centre et le rayon de la pupille, ce qui exige une détection grossière de la pupille. Cette étape est considérée comme une étape clef car toute mauvaise détection de la pupille engendre un échec de la segmentation de l'iris. Il est bien connu que la zone de la pupille est la région la plus sombre dans ce type d'images. Néanmoins, l'image oculaire peut présenter d'autres régions sombres comme les cils, les cheveux et les lunettes. Ces facteurs indésirables vont être fusionnés dans l'image de classes avec la région de la pupille ce qui se traduit par une mauvaise localisation de la pupille et par conséquent des erreurs de localisation des frontières de l'iris comme le montre dans la Figure 5.2.




FIGURE 5.2 – Exemple de mauvaises détections de la pupille par OSIRIS-V4. La localisation de la pupille détectée par OSIRIS-V4 sur les images en régions (première colonne) est reportée sur les images originale (deuxième colonne) et présentée par un cercle rouge.

Pour cette raison, nous avons proposé une nouvelle méthode de détection de la pupille plus adaptée aux images segmentées en classes. Notre but est d'identifier le centre et le rayon de la pupille notés  $(x_c, y_c, r)$  pour initialiser l'algorithme proposé dans OSIRIS-V4 pour déterminer les centres de l'iris. Pour atteindre cet objectif, nous avons utilisé les projections verticales et horizontales cumulées (Figure 5.3).

Soit  $B_n$  une image binaire de taille  $l * c$ , qui représente la région de la pupille extraite de l'image des classes résultante de la segmentation non supervisée par les Chaînes de Markov. Soit  $V = \{V_1, \dots, V_l\}$  la projection verticale cumulée de  $B_n$  avec  $V_j = \sum_{i=1}^c B_n(i, j)$  et  $H = \{H_1, \dots, H_c\}$  la projection horizontale cumulée de  $B_n$  avec  $H_i = \sum_{j=1}^l B_n(i, j)$ .

Nous considérons que le centre de la pupille  $(x_c, y_c)$  est le même que celui obtenu avec une

détection grossière de la pupille (Section 4.1.1). Nous mesurons la distance  $R_H$  entre  $x_c$  et la position du minimum global de la projection horizontale cumulée. Pour calculer la distance  $R_V$  nous cherchons le minimum global de la projection verticale cumulée. Nous imposons que sa position soit supérieure à  $y_c$ . La distance entre ces deux derniers représente la distance  $R_V$ . Enfin, le rayon de la pupille est la valeur minimale entre  $R_H$ ,  $R_V$  et le rayon maximal de la pupille noté  $R_m$ . L'approximation du rayon de la pupille  $r$  se formalise d'après :

$$\begin{aligned}
 r &= \min(R_H, R_V, R_m) \mid \text{avec} \\
 R_H &= |x_c - \arg \min_{1 \leq x_i \leq c}(H)| \text{ et} \\
 R_V &= |y_c - \arg \min_{y_c \leq y_i \leq r}(V)|
 \end{aligned} \tag{5.1}$$

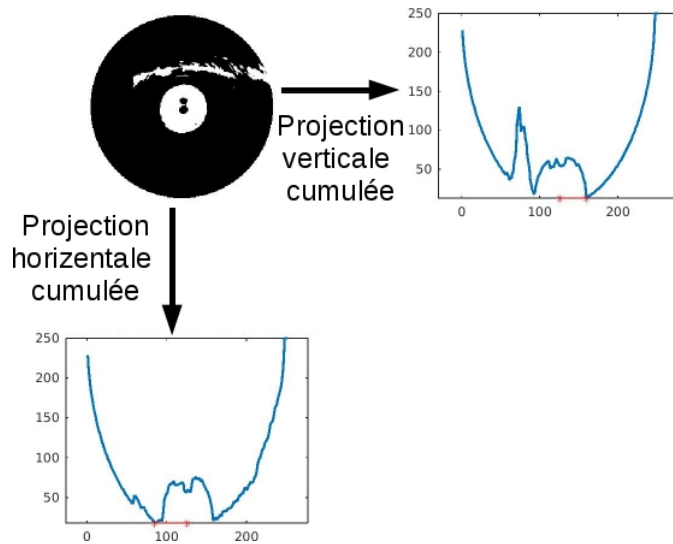


FIGURE 5.3 – Localisation de la pupille basée sur les projections cumulées.

Nous montrons dans la figure 5.4 les résultats de notre nouvelle méthode de localisation de la pupille sur les mêmes images illustrées dans la figure 5.2.




FIGURE 5.4 – Exemple de bonnes détections de la pupille sur les mêmes images que celles présentées dans la figure 5.2

### 5.2.2 Paramétrisation des contours

La deuxième étape du module de segmentation d'OSIRIS-V4 consiste à modéliser les contours de l'iris par des cercles. La Section 2.1.3 donne plus de détails sur cette modélisation. Nous rappelons que l'algorithme de Viterbi utilisé pour une recherche locale des contours de l'iris est appliqué en deux résolutions. Ces dernières permettent la recherche des deux types de contours : contours précis (haute résolution) et grossiers (faible résolution). En haute résolution tous les pixels sont pris en compte et en basse résolution, un sous échantillonnage irrégulier est appliqué afin de ne prendre que les points du contours iris/sclera et d'exclure les points appartenant aux régions des paupières et des cils, pouvant correspondre à du bruit. La méthode des moindres carrés est utilisée pour définir les contours de l'iris par des cercles.



Nous rappelons encore que les paramètres finaux du contour de l'iris sont ceux calculés sur les contours grossiers. Tandis que, les contours précis sont utilisés pour construire le masque de l'iris. La figure 5.5(a) montre les cercles trouvés par application de cet algorithme sur l'image des classes produite par le modèle HMC. Les mêmes cercles sont redessinés sur l'image originale dans la figure 5.5(b).




FIGURE 5.5 – Cercles estimés par OSIRIS-V4 sur l'image de classes. Affichés sur l'image des classes (a) Affichés sur l'image originale (b).

### 5.2.3 Construction du masque de l'iris

La dernière étape du module de segmentation d'OSIRIS-V4 consiste en la création du masque de l'iris. Pour ce faire, les contours trouvés dans l'étape précédente sont exploités. Les contours précis de la pupille et de l'iris sont utilisés pour masquer la région de l'iris. On observe fréquemment que le contour iris/sclera n'ajuste pas les frontières iris/paupières (inférieures et/ou supérieurs) dans les cas des occlusions. De plus, ce masque ne permet pas de supprimer toutes les occlusions et les réflexions lumineuses. Un seuillage adaptatif est ajouté pour produire un masque des pixels non détectés par le premier masque. La Figure 5.6 présente les différents masques appliqués pour la construction du masque final de l'iris. Cependant, la figure 5.7 montre des exemples pour lesquels le masque résultant n'est pas suffisant.




FIGURE 5.6 – Masque de l’iris résultant du module de segmentation d’OSIRIS-V4. Affichage des contours précis sur l’image Originale (a). Masque de la région de l’iris par les contours précis (b). Masque des autres occlusions par le seuillage adaptatif (c). Masque final de l’iris (d).




FIGURE 5.7 – Masques de l’iris non précis résultants du module de segmentation d’OSIRIS-V4. Affichage des contours précis sur l’image Originale (a) et (c). Masque final de l’iris (b) et (d).

### 5.2.4 Modules de reconnaissance

Pour la reconnaissance proprement dite de l'iris nous appliquons les modules standards proposés par Daugman (43) : normalisation, extraction des caractéristiques et comparaison des motifs. La zone de l'iris est normalisée en utilisant les frontières de l'iris modélisées par des cercles selon le modèle de *rubber sheet*. Il en résulte une représentation de l'iris par un rectangle de taille fixe prédéfinie. Ensuite, l'image normalisée est filtrée par des filtres 2D-Gabor de différentes résolutions et orientations pour extraire les caractéristiques de la texture de l'iris. Pour calculer les scores de correspondance, nous utilisons la distance de Hamming. Il faut Noter que ces trois modules sont implémentés dans le système de référence OSIRIS-V4 et que nous les utilisons en l'état dans ce travail.

## 5.3 Évaluation des Chaînes de Markov pour la reconnaissance de l'iris

### 5.3.1 Limitation de la méthode d'initialisation par histogramme

Dans cette section, les meilleurs modélisations de segmentations non supervisées basées sur les chaînes de Markov (HMC et HMC-SOP) ont été évaluées pour la reconnaissance de l'iris. Cette évaluation a été effectuée sur de grandes bases de données nommées ICE-2005 et CASIA-IrisV4-distance. Nous avons montré dans le chapitre précédent qu'une bonne initialisation améliore les résultats de la modélisation basée sur le modèle HMC et que l'initialisation d'histogramme est la plus convaincante pour initialiser le modèle HMC. Cependant nos premiers essais ont montré, sur la base de données CASIA-IrisV4-distance, l'inefficacité de la méthode. En effet, l'une des difficultés réside dans le faible contraste entre les frontières de l'iris et la sclera que nous l'avons remarqué dans de nombreuses images. Ceci se traduit par la fusion de la région d'iris et celle de la sclera lors de l'utilisation de la méthode d'initialisation par d'histogramme (figure 5.8).

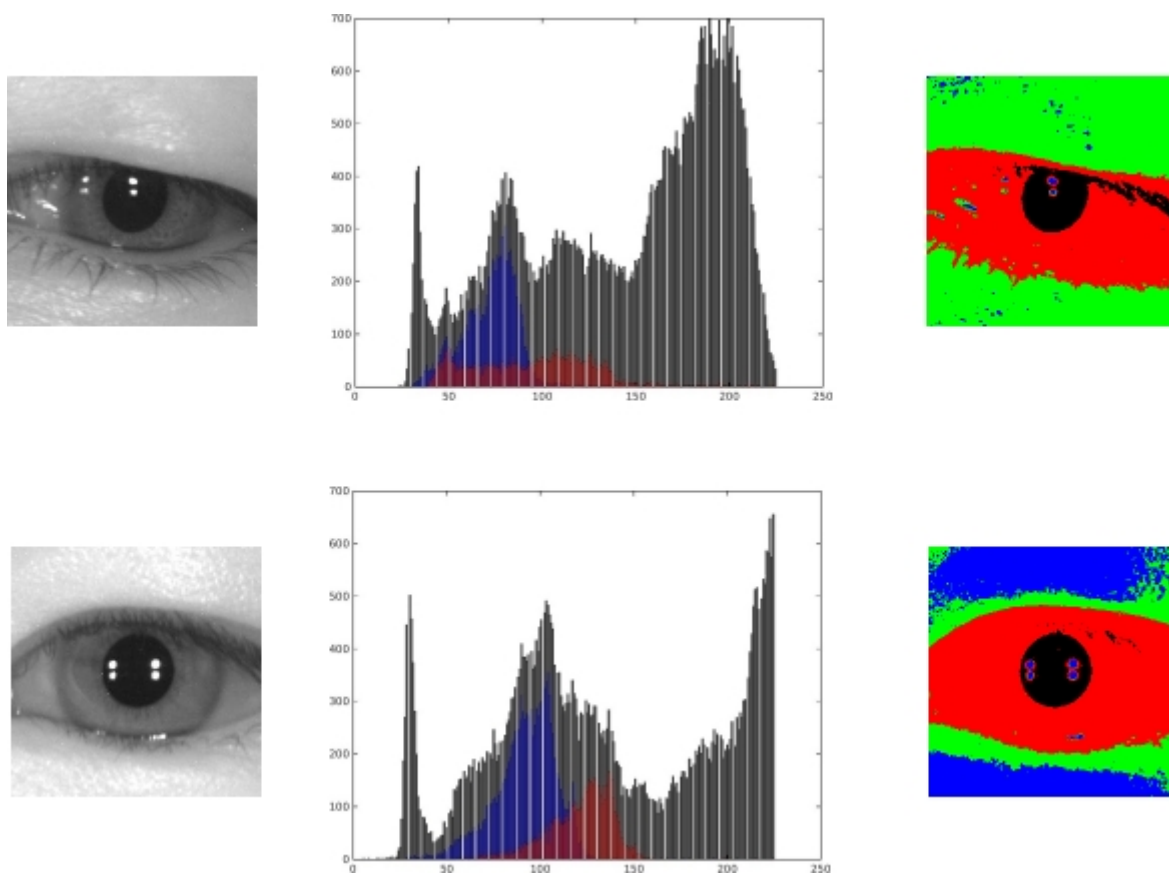


FIGURE 5.8 – Exemples de mauvaise initialisation par histogramme. De gauche à droite : image originale, histogramme de l'image avec les niveaux de gris de l'iris en bleu et ceux de sclera en rouge, segmentation par histogramme.

Pour utiliser la même modélisation markovienne (même méthode d'initialisation, même parcours, même modèle) pour segmenter les deux bases de données traitées dans ce chapitre, nous avons proposé d'explorer la même idée que celle proposée par (107) et utiliser une méthode supervisée pour apprendre les régions recherchées. Cette dernière est utilisée pour initialiser les modèles statistiques par la suite. C'est vrai que les performances des méthodes supervisées sont meilleures que celles non supervisées mais nous soulignons que notre but dans cette étape n'est pas de produire une segmentation fine mais une segmentation grossière de l'image d'iris.

Nous précisons que l'utilisation d'une méthode non supervisée pour initialiser les para-

mètres est la solution idéale mais vu la difficulté des images de l'iris et la variation d'acquisition des bases, il semble difficile de trouver une méthode non supervisée qui produit globalement une bonne initialisation.

Afin de réaliser une segmentation grossière par une méthode supervisée, nous avons choisi empiriquement un réseau de neurones avec trois couches. La première couche est composée de cinq neurones codant les caractéristiques de chaque pixel : position du pixel, intensité du pixel, moyenne et écart-type d'une région locale d'un rayon égal à trois. La couche cachée contient sept neurones et la couche de sortie est composée de quatre neurones qui représentent les régions recherchées.

Le modèle neuronal doit être appris différemment sur chaque base de données car leur qualité en terme de contraste est très différente. Pour ICE-2005, nous avons donc appris le réseau de neurones sur 91 images sélectionnées manuellement à partir de 2953 images. Pour la base CASIA-IrisV4-distance, nous avons sélectionné des images des 10 premiers sujets comme dans l'article (128).

Il est connu que l'utilisation d'une méthode supervisée apporte une amélioration par rapport aux méthodes non supervisées mais elle n'est pas certaine. Pour vérifier cela, nous avons évalué les erreurs de segmentation moyennes  $\bar{E}$  et  $\bar{E}_{10}$  utilisées dans le chapitre précédent sur la base ICE-2005. Les résultats montrent une amélioration de la segmentation des images par ce réseau de neurones, comme il était attendu, en comparaison avec celle réalisée par l'initialisation par histogramme, soit 4.70% et 21.35% respectivement. En se basant, sur ce premier résultat, nous pouvons considérer que l'initialisation par le réseau de neurones peut s'avérer comme une bonne méthode d'initialisation du modèle HMC.

La modélisation finale basé sur le modèle HMC utilisée pour effectuer la segmentation non supervisée combine l'initialisation par réseau de neurones, le *parcours Escargot* et le modèle HMC qui sera nommée HMC\_SN dans la suite de ce rapport. Nous avons montré dans le chapitre précédent que la modélisation TMC-OSP\_SK est considérée comme la meilleure modélisation en comparaison aux autres modélisations basées sur le modèle TMC-SOP. Pour cette raison, nous évaluons la modélisation nommée TMC-OSP\_SK sur la reconnaissance de l'iris. Nous rappelons que cette dernière est basée sur l'initialisation Kmeans, le *parcours*

*Escargot* et le modèle TMC-OSP.

### 5.3.2 Évaluation des performances

Dans cette partie, nous voulons analyser l'impact de l'ajout d'une étape de segmentation en régions basée sur les chaînes de Markov, sur les performances de vérification sur de grandes bases de données ICE-2005 et CASIA-IrisV4-distance.

Plus précisément, nous comparons notre approche, qui utilise une segmentation de Markov non supervisée comme un prétraitement (Figure 5.9(a)), à celle d'OSIRIS-V4 qui effectue une détection du contour de l'iris sur les images originales en niveau de gris (Figure 5.9(b)). Le seul facteur variable entre ces deux systèmes est le module de segmentation de l'iris. De plus, nous proposons une comparaison avec les méthodes d'approches similaires proposées dans la littérature. Les quatre méthodes (130), (105), (128) et (129) suivent un schéma identique pour trouver les contours sur les images de l'iris segmentées en deux classes (iris/non iris). La figure 5.9(c) décrit les différents modules composant les différents systèmes décrits dans (128). Le système proposé par (129) est illustré dans la figure 5.9(d). Nous notons que la méthode décrite (130), classée en première position à NICE-I, constitue une bonne référence pour la comparaison.

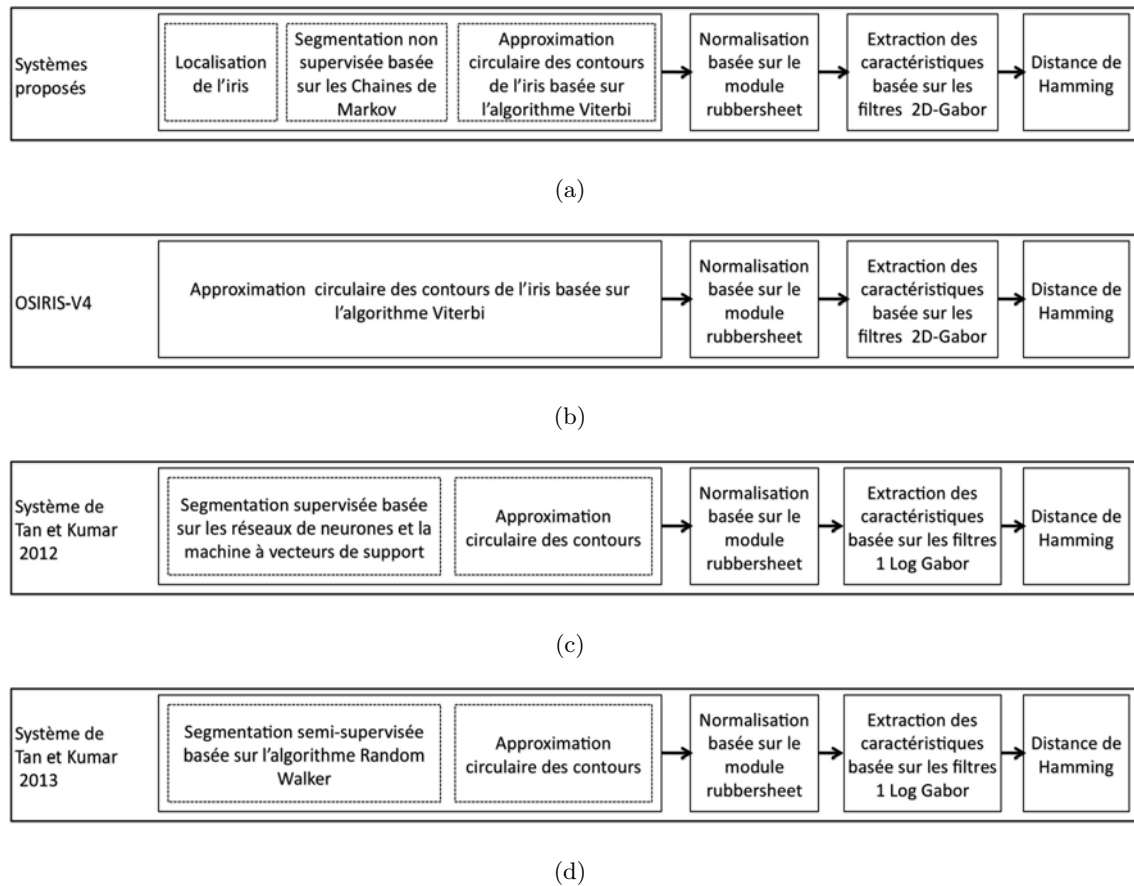


FIGURE 5.9 – Organigramme des différents systèmes de reconnaissance de l'iris utilisés dans ce travail.

Les premières expériences ont été effectuées sur la base CASIA-IrisV4-distance. Nous estimons le taux d'erreur égale (EER) et le taux d'acceptation de clients ( $GAR$ )<sup>1</sup> à  $10^{-3}$  et  $10^{-4}$  du taux de fausses acceptations ( $FAR$ ). Les résultats sont présentés dans le tableau 5.1. Nous avons également rapporté le  $GAR$  à  $FAR = 10^{-3}$  et  $FAR = 10^{-4}$  des méthodes de la littérature (130), (105), (128), (129) et cités dans (128) et (129).

Nous observons dans le tableau 5.1 que l'utilisation d'une pré-segmentation non supervisée basée sur le modélisation HMC\_SN dans le système de référence OSIRIS-V4 améliore les performances par rapport au système générique et par rapport à certaines méthodes de

1. il y a une différence entre les valeurs de  $GAR$  reportées dans ce manuscrit et celles publiées dans (142) du fait que depuis cette publication nous avons amélioré l'étape de la détection de la pupille décrite dans 4.1.1

vérification de l'iris dans la littérature testées dans ce travail. Il faut noter que contrairement à ce qui est fait dans(128), où la segmentation en région est totalement supervisée, la supervision dans notre approche ne permet qu'une segmentation approximative des classes. Elle sert uniquement d'initialisation en vue d'une segmentation non supervisée qui permet d'affiner la détection de région.

A partir de ces résultats, nous constatons que les performances de la modélisation TMC-OSP\_SK restent moins bonnes que celles obtenus par OSIRIS-V4.

TABLE 5.1: Comparaison de performances des systèmes proposés avec d'autres systèmes proposés dans la littérature sur la base CASIA-IrisV4-distance.

	OSIRIS-V4	HMC_SN+ +OSIRIS-V4	TMC-OSP_SK +OSIRIS-V4	(130)	(105)	(128)	(129)
EER	0.08	<b>0.07</b>	0.08	-	-	-	-
GAR à FAR= $10^{-3}$	0.71	<b>0.75</b>	0.70	$\leq 0.05$	$\leq 0.05$	$\approx 0.6$	$\approx 0.1$
GAR à FAR= $10^{-4}$	0.61	<b>0.66</b>	0.57	$\leq 0.05$	$\leq 0.05$	$\approx 0.1$	-

Pour compléter cette analyse, la Figure 5.10 montre les courbes ROC des modélisations proposées par rapport au système de référence OSIRIS-V4. Nous pouvons voir qu'à  $FAR = 10^{-3}$  et qu'à  $FAR = 10^{-4}$  une amélioration significative en terme de performance de vérification, respectivement ( $GAR = 0,75, GAR = 0,66$ ), est atteinte par la modélisation HMC\_SN par rapport à OSIRIS-V4 ( $GAR = 0,71, GAR = 0,61$ ). La modélisation TMC-OSP\_SK dégrade surtout les performances de vérification ( $GAR = 0,56$ ) à  $FAR = 10^{-4}$  par rapport à Osiris-V4( $GAR = 0,61$ ) .



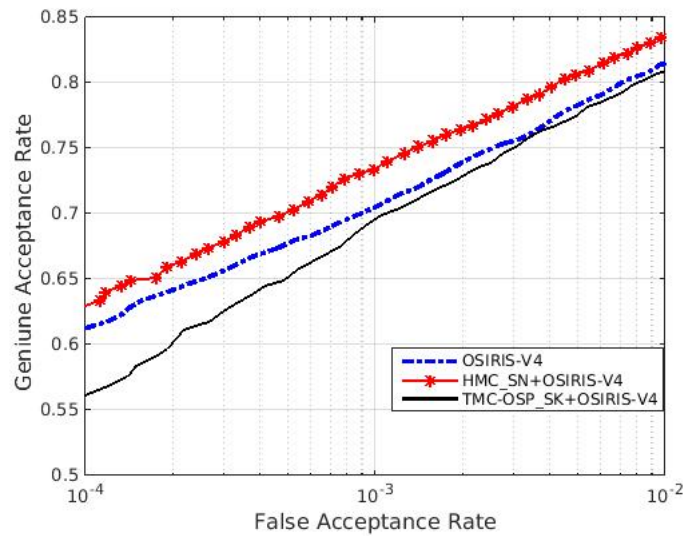


FIGURE 5.10 – Comparaison des performances des systèmes proposés dans cette thèse et OSIRIS-V4 sur la base CASIA-IrisV4-distance (courbe ROC).

Pour la base de données ICE-2005, le tableau 5.2 montre que l’approche basée sur le modèle HMC préserve les performances de vérification du système générique OSIRIS-V4. Cependant, aucune amélioration réelle ne peut être signalée. Cela peut être dû au fait que cette base de données ne contient pas assez d’images difficiles.

Nous observons le même comportement pour le modèle TMC-OSP\_SK sur la base CASIA-IrisV4-Distance, c’est à dire une dégradation des performances de vérification ( $GAR = 0,879$ ) à  $FAR = 10^{-4}$  par rapport à Osiris-V4( $GAR = 0,940$ ).

TABLE 5.2: Comparaison des performances des systèmes proposés dans cette thèse et d’OSIRIS-V4 sur la base ICE-2005.

	OSIRIS-V4	HMC_SN+ OSIRIS-V4	TMC-OSP_SK+ OSIRIS-V4
GAR à $FAR=10^{-3}$	<b>0.966</b>	0.964	0.951
GAR à $FAR=10^{-4}$	0.940	<b>0.942</b>	0.879

Suite à cette étude, nous pouvons conclure que pour la segmentation des images de l'iris, il serait préférable d'utiliser une bonne initialisation et faire tourner le modèle simple HMC pour raffiner l'initialisation que d'utiliser le modèle complexe TMC-OSP\_SK.

### 5.3.3 Évaluation des temps de calcul

Le module de segmentation de l'iris proposé se compose de deux étapes : la segmentation non supervisée et l'approximation des contours. L'approximation des contours est implémentée en C++. La segmentation non supervisée nécessite deux étapes : l'estimation des paramètres qui est implémentée en C et la restauration du signal, qui est implémentée en Matlab. Le module de segmentation fonctionne sur un processeur Intel 3,6 GHz. Le temps moyen de segmentation par image est d'environ 142,32 secondes pour la base de données ICE-2005 et de 61,98 secondes pour la base CASIA-IrisV4-distance. Deux paramètres affectent la durée de traitement, le premier est la longueur de la chaîne extraite de l'image de l'iris et le second est le nombre d'itérations nécessaires pour que l'algorithme SEM converge. Nous pouvons expliquer la différence de temps de traitement sur ces deux bases de données par le fait que la longueur des chaînes extraites à partir des images n'est pas la même dans les deux cas. En effet, les images résultant de la localisation grossière de l'iris sont basées sur son rayon maximal. Celui-ci est plus petit que celui des images de la base ICE-2005, dans les images de la base CASIA-IrisV4-distance.

Comme le montre le tableau 5.3, la segmentation non supervisée basée sur le modèle HMC requiert un temps de traitement important. Ceci peut être expliqué par l'utilisation d'une méthode itérative appliquée à chaque pixel pour estimer les paramètres par la méthode SEM et la restauration du signal par l'algorithme MPM.

D'autre part, le temps de traitement moyen par image de la base CASIA-IrisV4-distance rapportée dans (128) (basé sur les caractéristiques Zernike localisées calculées pour chaque pixel) et cité dans (129) est d'environ 368,2 Secondes. Par conséquent, notre segmentation peut être considérée comme efficace lorsqu'elle est comparée à cette méthode, qui est également basée sur une analyse au niveau des pixels.

TABLE 5.3 – Temps moyen de traitement.

	Temps moyen de traitement (seconde)/image		
	HMC_SN+ OSIRIS-V4		OSIRIS-V4
	segmentation non supervisée (Section 4.1)	approximation de contours (Section 5.2.2)	
ICE-2005	142.08	0.24	0.41
CASIA-IrisV4-distance	61.84	0.14	0.27

## 5.4 Impact du sous échantillonnage sur les performances et les temps de calculs

Dans la section précédente, nous avons montré que la segmentation non supervisée proposée basée sur le modèle HMC est très coûteuse en terme de temps de calcul et elle dépend de la taille de la chaîne traitée. Dans cette section, nous expliquons comment nous avons remédié à cet inconvénient.

Nous proposons d'estimer les paramètres du modèle HMC sur un sous-échantillon de pixels pour diminuer le nombre de pixels à traiter et par conséquent, diminuer le temps de calcul. Par la suite, nous utilisons ces paramètres pour restaurer une image segmentée ayant la même résolution que l'image originale. Par conséquent, le reste du processus de vérification sera semblable à celui proposé dans la Section 5.3.2.

Nous proposons de tester deux méthodes de sous-échantillonnage. La première consiste à sous-échantillonner l'image. La deuxième consiste à un sous-échantillonnage de la chaîne extraite par le *parcours Escargot*.

### 5.4.1 Sous-échantillonnage de l'image

Dans cette partie, nous nous intéressons à étudier la segmentation des images à différentes échelles. Nous réalisons un sous-échantillonnage de l'image originale avec différentes échelles

(1/2, 1/4, 1/6, 1/8, 1/10). La résolution de l'image à une échelle égale à 1/2 possède deux fois moins de pixels que celle à une échelle égale à 1. Ensuite, nous analysons l'impact de ce sous-échantillonnage sur les performances du système de reconnaissance de l'iris mesurées par le  $GAR$  à  $FAR = 10^{-3}$  et sur le temps de traitement moyen du module de segmentation non supervisée.

Les différentes expériences réalisées sur les bases de données ICE-2005 et CASIA-IrisV4-distance (Tableau 5.4) montrent que l'utilisation d'un sous-échantillonnage de l'image pour estimer les paramètres a non seulement l'avantage de réduire le temps moyen de traitement, mais aussi de ne pas affecter la performance  $GAR$ <sup>2</sup>. En effet, nous pouvons voir dans la Table 5.4 qu'il est possible de réduire la résolution de l'image d'un facteur 10 sans dégrader la performance. Ainsi, un gain significatif de temps de traitement moyen (environ 86%) peut être obtenu sur les bases de données ICE-2005 et CASIA-IrisV4-distance.

Le fait que le  $GAR$  ne soit pas modifié d'une façon significative peut être expliqué par le fait que le sous-échantillonnage des images ne modifie pas trop les paramètres finaux du modèle HMC. Le sous-échantillonnage préserve les régions d'origine de l'image et grâce à notre *parcours escargot* qui conserve les propriétés statistiques (transitions entre les classes) de la chaîne extraite de l'image.

---

2. il y a une différence entre les valeurs de  $GAR$  reportées dans ce manuscrit et celles publiées dans (142) du fait que depuis cette publication nous avons amélioré l'étape de la détection de la pupille décrite dans 4.1.1

TABLE 5.4 – Performances et gains de temps correspondant à différentes échelles de sous échantillonnage de l'image originale.

	Scale	1	1/2	1/4	1/6	1/8	1/10
ICE-2005	$GAR$ à $FAR = 10^{-3}$	0.964	0.966	<b>0.969</b>	0.968	0.968	0.965
	Temps moyen/image (seconde)	142.09	56.45	39.68	28.78	22.10	18.57
	Gain du temps(%)	–	60.27	72.07	79.74	84.44	86.93
	Nombre moyen des itérations	92.14	103.27	110.86	117.20	119.22	123.53
CASIA-IrisV4- distance	$GAR$ à $FAR = 10^{-3}$	<b>0.756</b>	0.747	0.751	0.752	0.747	0.752
	Temps moyen/image (seconde)	61.84	32.95	16.25	15.81	13.28	8.64
	Gain du temps(%)	–	46.71	73.72	74.43	78.52	86.02
	Nombre moyen des itérations	89.72	98.84	110.40	119.02	119.43	122.90

#### 5.4.2 Sous-échantillonnage de la chaîne

La deuxième méthode proposée permet de diminuer la taille des données à traiter et consiste à réaliser un sous-échantillonnage de la chaîne extraite par le *parcours Escargot*. Nous réalisons un sous-échantillonnage avec différents pas (2,4,6,8,10) comme illustré dans la Figure 5.11. Nous souhaitons, toujours, analyser l'impact du sous-échantillonnage de la chaîne sur les performances de reconnaissance de l'iris et le temps moyen de calcul.

Les résultats du tableau 5.5 montrent clairement que le sous-échantillonnage de la chaîne pour estimer les paramètres réduit le temps moyen du calcul sans détérioration des performances de reconnaissance de l'iris. De manière similaire au sous-échantillonnage de l'image, nous avons obtenu un gain significatif du temps du calcul (plus de 81%) pour les deux bases de données testées en ne considérant qu'un dixième de la chaîne.

En conclusion, si nous comparons les résultats reportés dans les deux tableaux 5.4 et 5.5, nous observons que l'estimation des paramètres dans le cas du sous-échantillonnage image ou chaîne est très intéressante pour de la reconnaissance de l'iris. Nous pouvons remarquer que le sous-échantillonnage de la chaîne peut être considéré meilleur que le sous-échantillonnage de l'image en terme de performance de reconnaissance mais moins bon en terme de gain du temps moyen du calcul.




FIGURE 5.11 – Illustration du sous-échantillonnage de la chaîne. La ligne en blanc est la chaîne complète. Les étoiles jaunes représentent les pixels considérés.

TABLE 5.5 – Performances et gains de temps correspondant à différents pas de sous échantillonnage de la chaîne originale.

	Pas	1	2	4	6	8	10
ICE-2005	$GAR$ à $FAR = 10^{-3}$	0.964	0.968	0.970	0.970	0.968	<b>0.972</b>
	Temps moyen /image (seconde)	142.09	61.88	55.58	40.42	28.73	22.33
	Gain du temps(%)	–	56.45	60.88	71.55	79.78	84.28
	Nombre moyen des itérations	92.14	103.24	114.69	121.08	123.9	126.30
CASIA-IrisV4-distance	$GAR$ à $FAR = 10^{-3}$	0.756	0.751	0.771	0.766	0.766	<b>0.774</b>
	Temps moyen/image (seconde)	61.84	36.39	24.09	15.92	13.08	11.27
	Gain du temps(%)	–	41.15	61.04	74.74	78.85	81.78
	Nombre moyen des itérations	89.72	102.66	119.14	123.11	128.13	131.97

## 5.5 Conclusion

Dans ce chapitre, nous avons détaillé notre méthodologie pour la reconnaissance de l'iris en NIR. Elle est basée sur l'utilisation des modèles statistiques pour effectuer une segmentation non supervisée des images oculaires en régions. Nous avons étudié deux modélisations basées sur les modèles statistiques HMC et TMC. Nous avons comparé et analysé les performances des modélisations proposées avec celles de la littérature. Les performances les plus intéressantes sont obtenues en utilisant la modélisation basée sur le modèle HMC. Enfin, nous avons proposé une estimation des paramètres du modèle HMC sur une version sous-échantillonnée de l'image ou de la chaîne. Cette mise en œuvre produit un gain significatif en terme de temps moyen du traitement sans dégradation des performances de vérification. Ces résultats confirment également la robustesse du modèle HMC proposé pour segmenter les images dégradées de l'iris.

Nous avons par ailleurs focalisé notre étude sur les images des yeux en NIR. Cependant, les images oculaires prises en lumière visible sont considérées plus dégradées que les images oculaires en NIR et difficiles à segmenter en raison des variations sévères d'illumination. Par conséquent, le chapitre suivant est dédié à l'étude de l'impact de l'utilisation du modèle statistique pour la segmentation non supervisée des images de l'iris prises en lumière visible.

## Chapitre 6

# Mise en œuvre de la segmentation des images d’iris en couleur

---

<b>6.1</b>	<b>Introduction</b>	<b>142</b>
<b>6.2</b>	<b>Modélisation des chaînes de Markov cachées vectorielles</b>	<b>144</b>
6.2.1	Définition des chaînes de Markov cachées vectorielles	144
6.2.2	Estimation des paramètres des chaînes de Markov cachées vectorielles	144
6.2.3	Restauration des chaînes de Markov cachées vectorielles	146
6.2.4	Conception des chaînes de Markov cachées vectorielles pour la segmentation non supervisée de l’iris en couleur	146
<b>6.3</b>	<b>Évaluation des Chaînes de Markov pour la segmentation de l’iris en couleur</b>	<b>146</b>
6.3.1	Segmentation d’une image monospectrale	149
6.3.2	Segmentation d’une image multispectrale	151
6.3.3	Comparaison avec les méthodes existantes	153
<b>6.4</b>	<b>Conclusion</b>	<b>155</b>

---



## 6.1 Introduction

L'UTILISATION des appareils intelligents (ordinateurs, téléphones, tablettes, appareil de photos, etc.) est devenue aujourd'hui une routine dominante dans la vie quotidienne. Ces appareils stockent une quantité énorme d'informations personnelles et professionnelles. La recommandation des technologies d'identifications biométriques est devenue fondamentale pour assurer la sécurité de ces informations. Ces appareils et surtout les téléphones disposent de caméras, ce qui rend l'utilisation de l'iris comme modalité biométrique accessible. La majorité des caméras embarquées utilise la lumière visible qui peut être perçue naturellement par l'œil humain et permet de reproduire les caractéristiques réelles observables de l'iris comme par exemple sa couleur et sa texture. La figure 6.1 montre les mêmes exemples de l'iris acquis en visible et NIR. Le besoin d'utiliser des technologies embarquées d'identification de l'iris sur appareils intelligents a mis en évidence l'importance de traiter des images de l'iris en couleur.

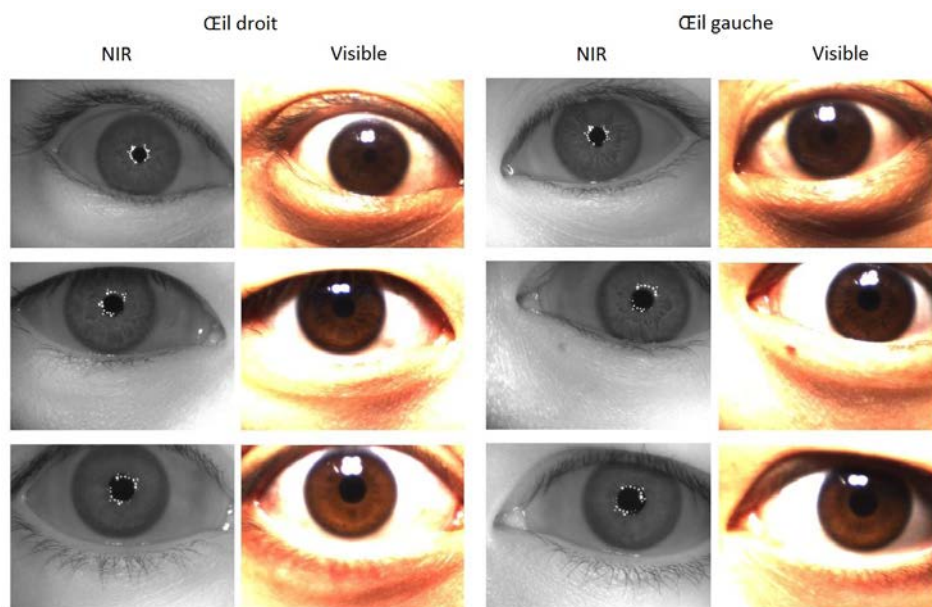


FIGURE 6.1 – Des images dégradées de l'iris prises en lumière visible et NIR avec une totale correspondance des pixels (90)

L'acquisition en lumière visible permet de produire une image plus riche en information, codée par trois canaux de couleur R (rouge), G (vert), et B (bleu) contrairement aux images produites par la lumière NIR qui est codée uniquement par les niveaux de gris. Malheureusement, elle engendre des dégradations sévères de la qualité des images oculaires. Les facteurs indésirables des images acquises en NIR, tels que la variation d'illumination, le faible contraste, les occlusions, les réflexions, se révèlent plus importants dans les images acquises en lumière visible (Section 1.3.1.2). Ces facteurs indésirables rendent la segmentation de l'iris plus difficile avec les approches standards décrites dans la littérature, qui se basent particulièrement sur la recherche du contour pupille/iris en premier lieu. La recherche de ce contour pupille/iris est difficile puisque la pupille n'est pas toujours la composante la plus sombre dans l'image de l'iris prise en lumière visible et qu'on observe le faible contraste pupille/iris dans les images de l'iris des yeux de couleur foncée. De même, la recherche du contour iris/sclera est compliquée pour les images aux yeux clairs qui présentent un faible contraste entre les deux régions iris et sclera à cause des fortes illuminations.

Notre analyse de l'état de l'art de la segmentation de l'iris en couleur présentée dans le chapitre 2 a montré que la plupart des travaux publiés explorent directement le canal rouge puisque c'est le canal le plus proche de l'infra-rouge. Cependant, Proença (105) a combiné différents canaux colorimétriques, le canal S de l'espace HSV et les canaux Cr et Cb de l'espace YCbCr pour apprendre la région de l'iris. Nous citons encore, les travaux (59), (5), (60) qui ont exploré directement les trois canaux R, G, B pour la segmentation de l'iris.

Dans ce chapitre, nous nous sommes intéressés à la segmentation non supervisée des images de l'iris en couleur. Au vu de l'information disponible, est-il préférable de traiter chaque composante indépendamment, de faire une sélection des composantes ou prendre en compte l'ensemble des trois composantes? Pour répondre à cette question, nous avons envisagé différents scénarios. Nous testons l'utilisation des différents canaux seuls comme une entrée du modèle HMC\_SN décrit dans le chapitre précédent. Pour tester la combinaison de différents canaux, nous avons dû étendre le modèle HMC\_SN pour prendre en compte plusieurs sources d'informations provenant des différents canaux en même temps.

## 6.2 Modélisation des chaînes de Markov cachées vectorielles

La modélisation markovienne nommée HMC\_SN que nous avons présentée et validée dans le chapitre précédent permet de segmenter d'une manière non supervisée des images de l'iris prises en lumière NIR. De ce fait, nous n'avons eu besoin que d'une modélisation monodimensionnelle. Cependant, l'extension de cette modélisation à une représentation multidimensionnelle de l'image est envisageable. Ceci pourra nous permettre de traiter des images de l'iris en couleur, donc représentées par trois canaux. Dans cette section, nous décrivons l'extension du modèle HMC\_SN au cas des images de l'iris en couleur. Pour cela, nous suivons la même démarche que celle utilisée dans le chapitre 3.

### 6.2.1 Définition des chaînes de Markov cachées vectorielles

Soit  $X = (X_n)_{n=1}^N$  un processus monodimensionnel caché qui prend ses valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_K\}$ , et soit  $Y = (Y_n)_{n=1}^N$  un processus observé  $D$ -dimensionnel, avec  $Y_n = (Y_n^d)_{d=1}^D$  dans  $\mathbb{R}$ . Nous supposons que  $X$  est une chaîne de Markov et que les composantes de  $Y$  sont indépendantes conditionnellement à  $X$ . Nous admettons que les composantes de  $Y_n$  sont corrélées. Selon le formalisme HMC, nous pouvons écrire la probabilité jointe comme suit :

$$p(\mathbf{z}) = p(x_1)p(y_1|x_1) \prod_{n=1}^{N-1} p(x_{n+1}|x_n)p(y_{n+1}|x_{n+1}) \quad (6.1)$$

La distribution  $p(y|x_n)$  (de  $y$  conditionnellement à  $x_n$ ) est modélisée par une loi gaussienne à  $M$  dimensions.

### 6.2.2 Estimation des paramètres des chaînes de Markov cachées vectorielles

Nous avons choisi de travailler dans un contexte non supervisé, donc l'estimation des paramètres est une étape nécessaire. Nous avons proposé d'utiliser la version adaptée de la méthode SEM aux chaînes de Markov vectorielles. Les différents paramètres de ce modèle sont représentés par les probabilités initiales  $\pi_i$  et les probabilités de transition  $c_{ij}$ . En plus, il

faut estimer  $K$  lois gaussiennes multivariées. Pour chaque loi, les paramètres sont représentés par le vecteur des moyennes  $\mu = \{\mu_i, \dots, \mu_D\}$  et la matrice de variance-covariance  $\Sigma$  de taille  $D \times D$ . Au total, il faut estimer  $(K^2 - 1) + K \times D + K \times (\frac{D^2+D}{2})$ . Le principe de la version adaptée de la méthode SEM est décrit dans l'algorithme 6.

- Initialisation des paramètres  $\theta^{(0)} = \{\pi^0, C^0, \mu^0, \sigma^0\}$

**Tant que** (le critère d'arrêt n'est pas atteint) **faire**

- Étape S : Simulation d'une réalisation  $x^{(q)} = \{x_1^{(q)}, \dots, x_N^{(q)}\}$  selon la loi *a posteriori*  $p(x|y, \theta^{(q)})$

- Étape E : Déduire la fonction  $\mathcal{Q}(\theta, \theta^{(q)})$

$$\mathcal{Q}(\theta, \theta^{(q)}) = \frac{1}{N} \sum_{n=1}^N p_{\theta^{(q)}}(X, Y, \theta | x^{(q)}, y) \quad (6.2)$$

- Étape M : ré-estimer  $\theta^{(q+1)}$

$$\pi_i^{(q+1)} = \frac{1}{N} \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)} \quad (6.3)$$

$$c_{ij}^{(q+1)} = \eta \sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i, x_{n+1}^{(q)} = \omega_j)} \quad (6.4)$$

$$\mu_{id}^{(q+1)} = \eta \sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)} y_n^d \quad (6.5)$$

$$\Sigma_i^{(q+1)} = \eta \sum_{n=1}^{N-1} \mathbb{1}_{(x_n^{(q)} = \omega_i)} \left( y_n - \mu_i^{(q+1)} \right) \left( y_n - \mu_i^{(q+1)} \right)^t \quad (6.6)$$

avec  $\eta = \frac{1}{\sum_{n=1}^N \mathbb{1}_{(x_n^{(q)} = \omega_i)}}$ ,  $(i, j) \in \{1, \dots, K\}^2$ ,  $j \in \Omega$  et  $d \in \{1, 2, \dots, D\}$

**Fait**

Algorithme 6: Principe de la méthode SEM dans une chaîne de Markov cachée vectorielle.

### 6.2.3 Restauration des chaînes de Markov cachées vectorielles

Nous rappelons que l'algorithme MPM décrit dans la Section 3.1.1.2 est utilisé pour la restauration du processus caché  $X$  à partir du processus observé  $Y$ . Cet algorithme maximise la probabilité marginale *a posteriori*. Nous soulignons que la seule différence entre le modèle HMC décrit dans le Chapitre 3 et les chaînes de Markov cachées vectorielles est la loi du bruit qui est considérée multivariée dans le cas de ce dernier. Par conséquent, toutes les équations décrites dans le Chapitre 3, Section 3.2.3 sont applicables pour le calcul de la probabilité marginale *a posteriori*. Le calcul de cette dernière offre la possibilité de calculer la décision bayésienne et donc la restauration du processus  $X$ .

### 6.2.4 Conception des chaînes de Markov cachées vectorielles pour la segmentation non supervisée de l'iris en couleur

Nous considérons une image de l'iris en couleur  $\mathbf{I}$  constituée de 3 images monospectrales R, G, B. L'application du *parcours Escargot* sur chacune des images monospectrales produit 3 chaînes. Ce modèle consiste à considérer deux processus aléatoires  $X$  et  $Y$  où  $X$  est un processus monodimensionnel. La variable cachée  $X_s$  du pixel  $s$  prend sa valeur dans l'ensemble des classes qui est défini *a priori*. Nous rappelons que dans notre cas, cet ensemble est composé des classes suivantes : pupille, iris, sclera, peau. Le processus  $Y$  est un processus multidimensionnel qui présente la variable observable  $Y_s$ . Cette dernière est représentée par un triplet de niveaux de gris correspondant aux valeurs R, G, B du pixel  $s$ .

La segmentation de ces images de l'iris en couleur est menée selon la décision bayésienne MPM après avoir estimé tous les paramètres du modèle et ceux du bruit par la méthode SEM adaptées aux chaînes de Markov cachées vectorielles.

## 6.3 Évaluation des Chaînes de Markov pour la segmentation de l'iris en couleur

Nous soulignons que les modèles proposés dans (130), (105), (128), (129), (65), (145), (78) (Voir Chapitre 2) pour la segmentation des images de l'iris capturées en lumière visible ont été

testés sur la base de référence UBIRIS-v2. Cette dernière souffre de plusieurs dégradations qui affectent directement la segmentation de l'iris. Aujourd'hui seules deux vérités terrain sont publiques. Elles ont été fournies par les créateurs de la base UBIRIS-v2 lors des deux compétitions NICE-I et NICE-II afin d'évaluer les méthodes proposées. Nous résumons dans le tableau 6.1 l'ensemble de tests employés pour chaque travail ainsi que l'erreur de segmentation moyenne  $\bar{E}$ . Nous rappelons que cette dernière est calculée comme suit :

$$\bar{E} = \left( \frac{1}{N} \sum_{i=1}^N E_i \right) \times 100 \quad (6.7)$$

avec :

$$E = \frac{1}{l \times c} \sum_{i=1}^l \sum_{j=1}^c \mathcal{G}(i, j) \otimes \mathcal{S}(i, j) \quad (6.8)$$

où  $l, c$  dénotent respectivement le nombre de lignes et de colonnes de l'image,  $\mathcal{G}$  représente la vérité terrain du masque de l'iris et  $\mathcal{S}$  représente le masque de l'iris trouvé par la méthode de segmentation proposée. L'opérateur XOR «  $\otimes$  » est utilisé pour évaluer le nombre de pixels différents entre  $\mathcal{G}$  et  $\mathcal{S}$ .

TABLE 6.1: Erreurs de segmentation moyennes  $\bar{E}$  de quelques travaux de la littérature récents testés sur les ensembles du test NICE-I et NICE-II.

	Ensemble du test NICE-I (500 images)	Ensemble du test NICE-II (1000 images)
(130)	1.31	3.49 <sup>1</sup>
(105)	—	3.75 <sup>1</sup>
(128)	—	1.90
(129)	—	1.76
(65)	1.24	—

1. reporté dans (128)
2. reproduit dans cette thèse par l'utilisation de son code (4)

(145)	1.71 <sup>2</sup>	1.21
(78)	0.9	—

Notre intention dans ce chapitre est d'explorer la possibilité d'effectuer une segmentation non supervisée des images de l'iris prises en lumière visible par des chaînes de Markov cachées. Sachant que la présence de certaines composantes de l'image oculaire où les différentes dégradations peuvent être plus facilement détectées dans certains canaux spectraux que d'autres. Pour cette raison, nous souhaitons savoir si l'utilisation d'un seul canal R, G, B permet, pourvu qu'il soit bien choisi, de mieux caractériser la région de l'iris par rapport aux trois canaux. Pour atteindre ce but, deux séries d'expériences ont été menées sur l'ensemble du test NICE-I. La première consiste à utiliser le modèle monodimensionnel HMC-SN pour tester les différents canaux R, G, B séparément. La deuxième teste le modèle vectoriel en combinant les trois canaux en un seul vecteur.

Pour la segmentation nous procédons comme précédemment pour les images en NIR. Nous localisons d'abord grossièrement la région de l'iris. Ensuite, nous effectuons une segmentation en régions par la modélisation markovienne. Puis, nous déterminons les contours de l'iris. Finalement, nous cherchons le masque de l'iris.

La méthode de détection grossière de la région de l'iris utilisée est celle que nous avons présentée dans la Section 4.1.1. Nous rappelons qu'elle est basée sur la recherche de la pupille puisque cette dernière est la région la plus sombre dans les images de l'iris prises en NIR. Toutefois, la pupille n'est pas toujours la région la plus sombre dans les images de l'iris en couleur. Pour cette raison nous avons adapté cette méthode aux images en couleur, et au lieu de rechercher la pupille nous recherchons l'iris. Le seuillage adaptatif a été remplacé par un Kmeans en 3 classes réalisé sur les trois canaux R, G, B. Le reste de la procédure est identique.

La segmentation en régions basée sur la modélisation markovienne est effectuée, par la suite, sur la région grossière de l'iris après avoir transformé l'image en chaîne en utilisant le *parcours Escargot*. Le modèle a été initialisé par le réseau de neurones présenté dans le chapitre précédent (Section 5.3.1). Le modèle a été appris sur 28 images de l'iris en couleur

de la base UBIRIS-v2. Nous rappelons que cette initialisation est grossière et le but de cette étape n'est justement pas de réaliser une segmentation fine.

Le module de segmentation d'OSIRIS-V4 (Section 2.1.3) a été adapté pour la recherche des contours de l'iris dans les images en couleur présegmentées par la modélisation markovienne. Nous procédons à la recherche du contours iris/sclera en premier lieu contrairement à la version originale où le contour pupille/iris est le premier à être détecté. Cette étape permet de modéliser les contours de l'iris par deux cercles. Comme nous l'avons expliqué dans la section 5.2.3, le système OSIRIS-V4 est conçu pour des images de l'iris en niveaux de gris et le masque de l'iris résultant par ce système n'est pas bon. Par conséquent nous utilisons dans cette partie le module de construction du masque du système décrit dans (145). Nous présentons dans la figure 6.7 le schéma général de ces différentes étapes.

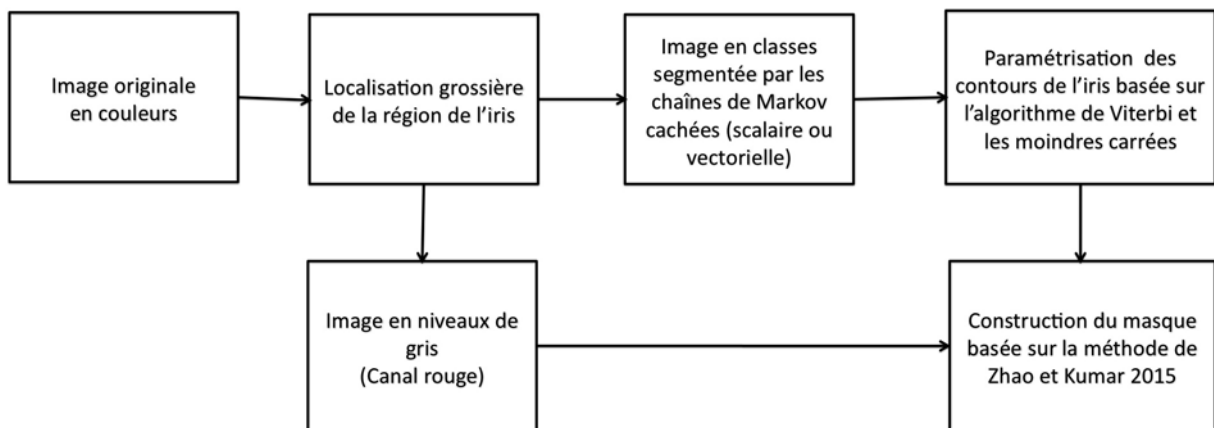


FIGURE 6.2 – Schéma général de traitement des images en couleur.

### 6.3.1 Segmentation d'une image monospectrale

L'objectif de cette section est d'examiner l'efficacité de la segmentation des images en couleur par le modèle HMC-SN. Dans ce cas de figure, nous traitons séparément les trois canaux R, G, B.

Les figures 6.3, 6.4 illustrent les résultats de segmentation par le modèle HMC-SN d'une image de l'iris de couleur sombre et une autre de couleur claire par l'utilisation des diffé-



rentes canaux. Nous remarquons que l'utilisation du canal R donne de bonnes segmentations par rapport aux autres canaux quelle que soit la couleur de l'iris. La séparation des deux régions iris et scléra par les différents canaux est relativement équivalente. La vraie différence apparaît clairement sur la détection de la région de la pupille. Nous savons que le contour pupille/iris est le contour le plus difficile à détecter dans les images de couleur sombres (Figure 6.3). Donc, isoler cette région facilite la détection de ce contour. Nous remarquons sur toute la base du test NICE-I que la segmentation de cette région par le modèle HMC\_SN en utilisant le canal R n'est pas parfaite. Ceci influence directement l'étape suivante qui vise à approximer les contours par des cercles.




FIGURE 6.3 – Segmentation d'une image de l'iris de couleur sombre par le modèle HMC\_SN. De gauche à droite : l'image en couleur, canal R, canal G, canal B ainsi que leur segmentation respective.




FIGURE 6.4 – Segmentation d’une image de l’iris de couleur claire par le modèle HMC\_SN. De gauche à droite : l’image en couleur, canal R, canal G, canal B ainsi que leur segmentation respective.

Le tableau 6.2 donne les erreurs de segmentation moyennes obtenues par chaque canal. Ces erreurs confirment nos remarques sur la qualité de segmentation produite par le canal R. Ce résultat est attendu, puisque le spectre de la couleur rouge est le plus proche du spectre NIR.

TABLE 6.2: Erreurs de segmentation moyennes  $\bar{E}$  produites par le modèle HMC\_SN sur l’ensemble du test NICE-I.

Canal	R	G	B
$\bar{E}$ (%)	1.70	1.83	1.95

### 6.3.2 Segmentation d’une image multispectrale

Cette section est consacrée au test de l’extension vectorielle du modèle HMC\_SN pour la segmentation des images de l’iris en couleur. L’expérience menée permet de prendre en considération les trois canaux en même temps.

De manière analogue, nous comparons la segmentation produite par le modèle HMC\_SN vectoriel et celle produite par le modèle HMC\_SN appliqué sur le canal R. Les figures 6.5, 6.6 et le tableau 6.3 illustrent que la fusion des trois canaux a un effet négatif sur le résultat de segmentation. Cela peut être expliqué par :

- La loi du bruit ne suit pas une loi gaussienne multivariée.
- La fusion de l'information provenant des deux canaux G et B peut amplifier le bruit ce qui se traduit par une mauvaise estimation des paramètres.




FIGURE 6.5 – Segmentation d'une image de l'iris de couleur sombre par les modèles HMC\_SN et HMC\_SN vectoriel. Première colonne : image en couleur et sa segmentation par HMC\_SN vectoriel. Deuxième colonne : canal R et sa segmentation par HMC\_SN.




FIGURE 6.6 – Segmentation d’une image de l’iris de couleur claire par les modèles HMC\_SN et HMC\_SN vectoriel. Première colonne : image en couleur et sa segmentation par HMC\_SN vectoriel. Deuxième colonne : canal R et sa segmentation par HMC\_SN.

TABLE 6.3: Erreurs de segmentation moyennes  $\bar{E}$  produites par le modèle HMC\_SN vectoriel sur l’ensemble du test NICE-I.

Canaux	(R, G, B)	R
$\bar{E}$ (%)	1.75	1.70

### 6.3.3 Comparaison avec les méthodes existantes

Nous souhaitons comparer notre méthode de segmentation des images en couleur avec d’autres méthodes récentes publiées dans la littérature utilisant l’ensemble de test NICE-I (Tableau 6.1).

Le tableau 6.1 montre que les méthodes (78), (130) et (65) surpassent la modélisation proposée. Nous rappelons que la méthode (78) utilise une approche d’apprentissage profond. Ce genre de méthodes a prouvé son efficacité ces dernières années dans plusieurs domaines.

La puissance de ces modèles explique la faible valeur de l'erreur de segmentation par rapport aux autres méthodes. Cependant cette méthode est très complexe et nécessite un nombre important de paramètres à régler. L'une des raisons qui explique la supériorité des deux méthodes (130) et (65) par rapport à la nôtre est leur capacité à détecter le cas où l'iris est complètement absent (œil fermé) dans les images oculaires.

La seule méthode qui ait un schéma proche du nôtre c'est celle de Zhao et Kumar (145). A savoir rechercher les contours sur l'image qui caractérise les principales composantes oculaires.

De plus, une comparaison avec le système OSIRIS-V4 que nous avons adapté pour les images en couleur permet aussi de se référer à un algorithme de référence. Nous procédons comme précédemment à la recherche des contours sur les images présegmentées en régions sauf que nous utiliserons directement le canal R de l'image en couleur. Il faut noter que la différence entre ces deux modules est seulement le choix de l'image en entrée.

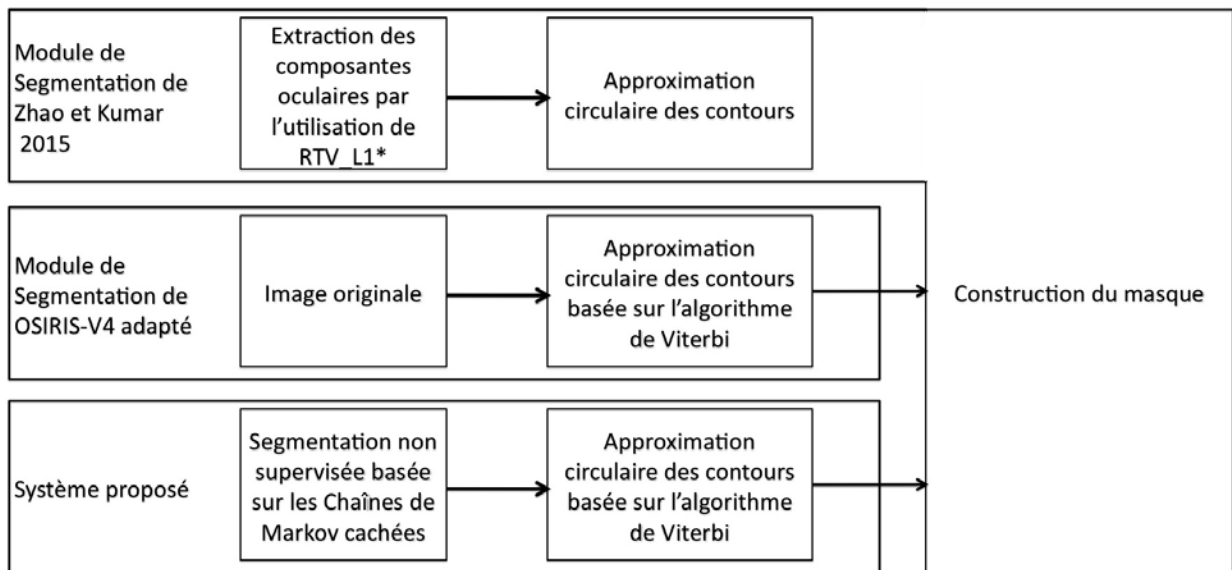


FIGURE 6.7 – Organigramme des différents modules de segmentations.

Comme précédemment, nous utilisons l'erreur de segmentation moyenne pour comparer les différents modules de segmentations présentés dans 6.7. Les résultats sont mentionnés dans le tableau 6.4. Nous remarquons que l'utilisation du modèle HMC<sub>SN</sub> sur le canal R pour produire une présegmentation en régions diminue l'erreur  $\bar{E}$ . De plus, nous constatons

que cette approche reste compétitive face à la méthode (145) qui a les meilleurs performances sur la base de test NICE-II.

TABLE 6.4: Erreurs de segmentation moyennes  $\bar{E}$  produites par le modèle HMC\_SN sur l'ensemble de test NICE-I.

Méthode	HMC sur le canal R	OSIRIS-V4	Zhao et Kumar 2015
$\bar{E}$	1.70	1.83	1.71

## 6.4 Conclusion

Dans ce chapitre, une extension vectorielle du modèle des chaînes de Markov cachées décrit dans le chapitre précédent a été présentée. Nous avons testé son application en segmentation non supervisée d'images de l'iris en couleur. Nous avons également testé la modélisation HMC\_SN sur chaque canal seul. Les résultats des différentes expériences permettent d'illustrer que le canal rouge contient l'information suffisante pour segmenter les images de l'iris acquis en lumière visible sans qu'il n'y ait besoin d'un recours à la modélisation vectorielle. Nous avons aussi montré les contours obtenus sur une image présegmentée par le modèle HMC\_SN sont meilleurs que la recherche des contours directement sur l'image originale.

Cette étude a montré que la présegmentation en région sur le canal R, par le modèle HMC\_SN améliore les performances sur la base considérée. L'étude comparative de notre méthode aux méthodes récentes de l'état de l'art a montré que la méthode proposée reste compétitive par rapport aux méthodes utilisant un schéma comparable au nôtre.

## Conclusions et perspectives

**N**ous avons abordé dans cette thèse le problème lié à la segmentation des images dégradées de l'iris. Nous proposons l'utilisation d'un modèle statistique pour effectuer une segmentation non supervisée en régions des images oculaires, afin de construire un module robuste de segmentation de l'iris. En particulier, notre originalité repose sur l'exploration des potentialités offertes par les modélisations markoviennes pour produire une segmentation non supervisée en régions.

Nous nous sommes limités dans ce travail aux chaînes de Markov qui nous ont semblé offrir un compromis en terme de performance et complexité. Notre étude porta sur les modèles de chaînes de Markov cachées, couples, et triplets. Notre première tâche consiste à examiner les différents facteurs entrant dans la configuration des différents modèles de chaînes étudiés et à analyser leur impact sur la qualité de la segmentation résultante. Cette étude a pris en compte à la fois la manière de linéariser l'image en un signal 1D et la méthode utilisée pour segmenter l'image en régions grossières afin d'initialiser les paramètres. L'étude a été validée sur la base ICE-2005 en comparant les différentes modélisations markoviennes proposées. Nous avons proposé une nouvelle approche pour linéariser l'image qui tient compte de la structure circulaire de l'iris. Nous avons montré que cette nouvelle méthode favorise l'obtention de segmentations plus précises par rapport à celles obtenues par la méthode de référence utilisée dans la majorité des travaux de la littérature. De plus, choisir adéquatement une segmentation pour initialiser les paramètres semble plus avantageux pour les HMCs que les PMCs et TMCs.

Nous avons ensuite proposé un module de segmentation non supervisée des images dégradées d'iris qui préserve un temps de traitement raisonnable. Ce module de segmentation a été intégré comme une première étape dans un système de reconnaissance de l'iris comme le système de référence OSIRIS-V4. Ce système a été adapté pour rechercher les contours de

l'iris sur la carte de gradient de l'image de régions résultant de l'étape de segmentation plutôt que sur l'image de niveaux de gris d'origine. Nos expériences montrent que ce nouveau système, lorsqu'il est testé sur les bases de données ICE-2005 et CASIA-IrisV4-distance, permet d'améliorer les performances de vérification par rapport à l'utilisation du système OSIRIS-V4. Il se compare également favorablement à d'autres systèmes récents de la littérature reposant sur des approches de segmentation supervisée de l'iris. Ces résultats intéressants mettent en évidence le potentiel d'utilisation des modèles statistiques pour produire une segmentation en régions en amont des approches basées sur la recherche des contours pour la segmentation de l'iris. L'utilisation d'une résolution d'image complète rend l'exécution lente, ce qui peut être considéré comme un handicap pour les applications en temps réel. Par conséquent, nous avons proposé d'estimer les paramètres du modèle HMC sur une version sous-échantillonnée de l'image ou de la chaîne, tout en gardant la résolution initiale pour le reste du processus. Cette mise en œuvre procure un gain significatif en terme de temps du traitement moyen sans dégradation des performances de vérification. Ces résultats confirment également la robustesse du modèle HMC proposé pour segmenter les images dégradées de l'iris.

Finalement, nous avons cherché à étendre la modélisation proposée à la segmentation des images prises en lumière visible. Nous avons donc utilisé une version vectorielle de la modélisation proposée basée sur les HMCs afin de réaliser une étude comparative entre l'utilisation de l'information provenant d'un ou de plusieurs canaux. Cette étude a été menée sur la base de test NICE-I. Les résultats montrent que l'application de notre méthode semble prometteuse pour la reconnaissance des images d'iris acquises en lumière visible.

## Perspectives

L'étude réalisée dans ce travail promet diverses intéressantes perspectives. Nous pouvons envisager une amélioration de la modélisation basée sur les chaînes de Markov cachées, proposée dans le chapitre 4, qui est très sensible à la méthode d'initialisation de paramètres. Nous avons considéré dans le chapitre 5, une méthode supervisée pour fournir une information *a priori*. Il serait judicieux d'utiliser une méthode complètement non supervisée et



qui ne dépend pas des images étudiées. Cela rendrait très intéressante l'intégration de cette modélisation dans une application biométrique.

Nous avons vu que le PMC testé dans le chapitre 4 a tendance à dégrader les performances de segmentation des images de l'iris. Ce modèle prend en compte la corrélation du bruit mais pas la non-stationnarité du processus caché et/ou du bruit. Donc, le test des modèles de chaîne de Markov couple M-stationnaire et MM-stationnaire décrits dans (20) peut être avantageux.

Toutes les modélisations testées dans ce travail de thèse sont basées sur une décision dure (appartenance à une seule classe). Nous pouvons envisager l'utilisation des modélisations markoviennes avec une décision floue (appartenance à toutes les classes avec certaines probabilités). Cette modélisation d'incertitude peut être formalisée parfaitement par la théorie d'évidence.

Nous avons fait l'hypothèse que la loi du bruit (les probabilités d'émission) suit une loi gaussienne. Nous pouvons dans un premier temps envisager de tester d'autres types de lois. Nous avons vu que la principale difficulté est la variation de la qualité des images de l'iris, qui dépend particulièrement aux conditions d'acquisition. Fixer la même loi du bruit pour toutes les images des différentes bases de données peut influencer négativement le résultat de la segmentation. Une des solutions est d'utiliser le mélange généralisé pour estimer le type de la loi du bruit (51). Une solution alternative consiste à estimer ces probabilités soit par l'utilisation d'un réseau de neurones multicouches comme il était proposé dans le cas de la reconnaissance de l'écriture (55), soit par l'utilisation d'un réseau de neurones conventionnel comme dans (72) pour la reconnaissance de signes.

Une autre possibilité qui consiste à étendre les différentes modélisations, étudiées dans le cadre de cette thèse, aux arbres de Markov qui permettent de faire un compromis entre les chaînes de Markov et les champs de Markov en terme de complexité calculatoire (88).

# Bibliographie

- [1] <http://imaios.com/fr/e-Anatomy/Tete-et-cou/Oeil-Illustrations>.
- [2] <http://iris.di.ubi.pt>.
- [3] [https://fr.wikipedia.org/wiki/Courbe\\_de\\_Peano#/.](https://fr.wikipedia.org/wiki/Courbe_de_Peano#/)
- [4] <http://www4.comp.polyu.edu.hk/~csajaykr/tvmiris.htm>.
- [5] A. F. Abate, M. Frucci, C. Galdi, and D. Riccio. BIRD : Watershed Based IRis Detection for mobile devices. *Pattern Recognition Letters*, 57 :43 – 51, 2015. Mobile Iris {CHallenge} Evaluation part I (MICHE I).
- [6] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Ssstrunk. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11) :2274–2282, Nov 2012.
- [7] F. H. Alder. *Physiologie of the Eye*. London : The C.V. Mosby Company, 4th edition, 1965.
- [8] A. B. Ashraf, S. C. Gavenonis, D. Daye, C. Mies, M. A. Rosen, and D. Kontos. A Multichannel Markov Random Field Framework for Tumor Segmentation With an Application to Classification of Gene Expression-Based Breast Cancer Recurrence Risk. *IEEE transactions on medical imaging*, 32(4) :637–648, 2013.
- [9] A. R. Backes, L. C. Gerhardinger, J. S. B. Neto, and O. M. Bruno. Medical image retrieval and analysis by Markov random fields and multi-scale fractal dimension. *Physics in medicine and biology*, 60(3) :1125, 2015.

- [10] L. E. Baum and J. A. Eagon. An inequality with applications to statistical estimation for probabilistic functions of Markov processes and to a model for ecology. *Bull. Amer. Math. Soc*, 73(3) :360–363, 1967.
- [11] L. E. Baum, T. Petrie, G. Soules, and N. Weiss. A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains. *The annals of mathematical statistics*, 41(1) :164–171, 1970.
- [12] M. Ben Mabrouk and W. Pieczynski. Unsupervised segmentation of random discrete data using triplet Markov chains. In *International Symposium on Applied Stochastic Models and Data Analysis*. Citeseer, 2007.
- [13] D. Benboudjema, N. Othman, B. Dorizzi, and W. Pieczynski. CHALLENGING EYE SEGMENTATION USING TRIPLET MARKOV SPATIAL MODELS. In *Acoustics, Speech and Signal Processing (ICASSP), IEEE International Conference on*, pages 1927–1931. IEEE, 2013.
- [14] B. Benmiloud and W. Pieczynski. Estimation des paramètres dans les chaînes de Markov cachées et segmentation d’images. *TS. Traitement du signal*, 12(5) :433–454, 1995.
- [15] A. Bertillon. LA COULEUR DE L’IRIS. In : *Annales de démographie internationale*, 1886.
- [16] J. Besag. On the Statistical Analysis of Dirty Pictures. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 259–302, 1986.
- [17] A. Bietti, F. Bach, and A. Cont. An online EM algorithm in hidden (semi-)Markov models for audio segmentation and clustering. In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1881–1885, April 2015.
- [18] J. Blanchet and F. Forbes. Triplet Markov Fields for the Classification of Complex Structure Data. *IEEE transactions on pattern analysis and machine intelligence*, 30(6) :1055–1067, 2008.

- [19] W. W. Boles and B. Boashash. A human identification technique using images of the iris and wavelet transform. *IEEE transactions on signal processing*, 46(4) :1185–1188, 1998.
- [20] M. E. Y. Boudaren. MODÈLES GRAPHIQUES ÉVIDENTIELS. Theses, Institut National des Télécommunications ; Université des sciences et de la technologie Houari Boumédiène (Alger), January 2014.
- [21] M. E. Y. Boudaren, E. Monfrini, and W. Pieczynski. Unsupervised Segmentation of Random Discrete Data Hidden With Switching Noise Distributions. *IEEE Signal Processing Letters*, 19(10) :619–622, 2012.
- [22] M. E. Y. Boudaren, E. Monfrini, W. Pieczynski, and A. Aïssani. Phasic Triplet Markov Chains. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 36(11) :2310–2316, Nov 2014.
- [23] M. E. Y. Boudaren and W. Pieczynski. Dempster-Shafer Fusion of Evidential Pairwise Markov Chains. *IEEE Transactions on Fuzzy Systems*, PP(99) :1–1, 2016.
- [24] M. E. Y. Boudaren, W. Pieczynski, and E. Monfrini. UNSUPERVISED SEGMENTATION OF NON STATIONARY DATA HIDDEN WITH NON STATIONARY NOISE. In *Systems, Signal Processing and their Applications (WOSSPA), 2011 7th International Workshop on*, pages 255–258. IEEE, 2011.
- [25] D. H. Brainard and B. A. Wandell. Analysis of the retinex theory of color vision. *JOSA A*, 3(10) :1651–1661, 1986.
- [26] S. Bricq, C. Collet, and J. Armspach. MS Lesion Segmentation based on Hidden Markov Chains. *Grand Challenge Work. : Mult. Scler. Lesion Segm. Challenge*, pages 1–9, 2008.
- [27] S. Bricq, C. Collet, and J. P. Armspach. Unifying framework for multimodal brain MRI segmentation based on Hidden Markov Chains. *Medical image analysis*, 12(6) :639–652, 2008.

- [28] M. Broniatowski, G. Celeux, and J. Diebolt. Reconnaissance de mélanges de densités par un algorithme d'apprentissage probabiliste. *Data analysis and informatics*, 3 :359–373, 1983.
- [29] H. Bunke and T. Caelli. *Hidden Markov Models : Applications in Computer Vision*, volume 45. World Scientific, 2001.
- [30] T. A. Camus and R. Wildes. Reliable and fast eye finding in close-up images. In *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, volume 1, pages 389–394. IEEE, 2002.
- [31] C. Carincotte, S. Derrode, and S. Bourennane. Unsupervised Change Detection on SAR Images Using Fuzzy Hidden Markov Chains. *IEEE Transactions on Geoscience and Remote Sensing*, 44(2) :432–441, Feb 2006.
- [32] CASIA. Chineseacademy of sciences institute of automation, CASIA-Iris. <http://biometrics.idealtest.org/findDownloadDbByMode.do?mode=Iris>, 2012.
- [33] M. Castrillón, O. Déniz, C. Guerra, and M. Hernández. ENCARA2 : Real-time detection of multiple faces at different resolutions in video streams. *Journal of Visual Communication and Image Representation*, 18(2) :130 – 140, 2007.
- [34] G. Celeux, D. Chauveau, and J. Diebolt. Stochastic versions of the EM algorithm : an experimental study in the mixture case. *Journal of Statistical Computation and Simulation*, 55(4) :287–314, 1996.
- [35] G. Celeux and J. Diebolt. The SEM algorithm : a probabilistic teacher algorithm derived from the EM algorithm for the mixture problem. *Computational statistics quarterly*, 2(1) :73–82, 1985.
- [36] G. Celeux and J. Diebolt. L'algorithme SEM : un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités. *Revue de statistique appliquée*, 34(2) :35–52, 1986.

- [37] G. Celeux and J. Diebolt. A random imputation principle : the stochastic EM algorithm. Technical Report RR-0901, INRIA, September 1988.
- [38] Y. Chen, M. Adjouadi, C. Han, J. Wang, A. Barreto, N. Rishe, and J. Andrian. A highly accurate and computationally efficient approach for unconstrained iris segmentation. *Image and Vision Computing*, 28(2) :261–269, 2010.
- [39] H. Cheng and Y. Sun. A hierarchical approach to color image segmentation using homogeneity. *IEEE Transactions on image processing*, 9(12) :2071–2082, 2000.
- [40] M. M. Cheng, N. J. Mitra, X. Huang, P. Torr, and S. M. Hu. Salient object detection and segmentation. *Image*, 2(3) :9, 2011.
- [41] R. Clarke. Human Identification in Information Systems : Management Challenges and Public Policy Issues. *Information Technology & People*, 7(4) :6–37, 12 1994.
- [42] J. B. Courbot, E. Rust, E. Monfrini, and C. Collet. Vertebra segmentation based on two-step refinement. *Journal of Computational Surgery*, 4(1) :1, 2016.
- [43] J. Daugman. High Confidence Visual Recognition of Persons by a Test of Statistical Independence. *IEEE transactions on pattern analysis and machine intelligence*, 15(11) :1148–1161, 1993.
- [44] J. Daugman. Biometric personal identification system based on iris analysis, March 1 1994. US Patent 5,291,560.
- [45] J. Daugman. How iris recognition works. *IEEE Transactions on circuits and systems for video technology*, 14(1) :21–30, 2004.
- [46] J. Daugman. New Methods in Iris Recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 37(5) :1167–1175, 2007.
- [47] D. Benboudjema and W. Pieczynski. Unsupervised image segmentation using triplet Markov fields. *Computer Vision and Image Understanding*, 99(3) :476 – 498, 2005.

- [48] J. P. DELMAS. RELATIONS ENTRE LES ALGORITHMES D'ESTIMATION ITERATIVES EM ET ICE AVEC EXEMPLES D'APPLICATION. In *15 Colloque sur le traitement du signal et des images, FRA, 1995*. GRETSI, Groupe d'Etudes du Traitement du Signal et des Images, 1995.
- [49] A. P. Dempster, N. M. Laird, and D. B. Rubin. Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 1–38, 1977.
- [50] S. Derrode and W. Pieczynski. Signal and Image Segmentation Using Pairwise Markov Chains. *IEEE Transactions on Signal Processing*, 52(9) :2477–2489, 2004.
- [51] S. Derrode and W. Pieczynski. Signal and Image Segmentation Using Pairwise Markov Chains. *IEEE Transactions on Signal Processing*, 52(9) :2477–2489, 2004.
- [52] S. Derrode and W. Pieczynski. Unsupervised data classification using pairwise Markov chains with automatic copulas selection. *Computational Statistics & Data Analysis*, 63 :81 – 98, 2013.
- [53] P. Devijver. Baum's forward-backward algorithm revisited. *Pattern Recognition Letters*, 3(6) :369 – 373, 1985.
- [54] A. Eric. Discrete circles, rings and spheres. *Computers and Graphics*, 18(5) :695 – 706, 1994.
- [55] S. Espana-Boquera, M. J. Castro-Bleda, J. Gorbe-Moya, and F. Zamora-Martinez. Improving Offline Handwritten Text Recognition with Hybrid HMM/ANN Models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(4) :767–779, April 2011.
- [56] A. Farihan, M. Raffei, H. Asmuni, R. Hassan, and R. M. Othman. Fusing the line intensity profile and support vector machine for removing reflections in frontal {RGB} color eye images. *Information Sciences*, 276 :104 – 122, 2014.

- [57] A. Farihan, M. Raffei, H. Asmuni, R. Hassan, and R. M. Othman. A low lighting or contrast ratio visible iris recognition using iso-contrast limited adaptive histogram equalization. *Knowledge-Based Systems*, 74 :40 – 48, 2015.
- [58] R. Fjortoft, Y. Delignon, W. Pieczynski, M. Sigelle, and F. Tupin. Unsupervised Classification of Radar Images Using Hidden Markov Chains and Hidden Markov Random Fields. *Geoscience and Remote Sensing, IEEE Transactions on*, 41(3) :675–686, March 2003.
- [59] M. Frucci, M. Nappi, and D. Riccio. *Watershed Based Iris SEgmentation*, pages 204–212. Springer Berlin Heidelberg, Berlin, Heidelberg, 2013.
- [60] M. Frucci, M. Nappi, D. Riccio, and G. S. di Baja. WIRE : Watershed based iris recognition. *Pattern Recognition*, 52 :148 – 159, 2016.
- [61] M. Gelgon and P. Bouthemy. A region-level motion-based graph representation and labeling for tracking a spatial image partition. *Pattern Recognition*, 33(4) :725–740, 2000.
- [62] S. Geman and D. Geman. Stochastic Relaxation, Gibbs Distributions and the Bayesian Restoration of Images. *IEEE Transactions on pattern analysis and machine intelligence*, (6) :721–741, 1984.
- [63] L. Grady. Random Walks for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(11) :1768–1783, Nov 2006.
- [64] M. Haindl and M. Krupička. Non-iris occlusions detection. In *Biometrics : Theory, Applications and Systems (BTAS), 2013 IEEE Sixth International Conference on*, pages 1–6, Sept 2013.
- [65] M. Haindl and M. Krupička. Unsupervised detection of non-iris occlusions. *Pattern Recognition Letters*, 57 :60 – 65, 2015.



- [66] Z. He, T. Tan, Z. Sun, and X. Qiu. Toward Accurate and Fast Iris Segmentation for Iris Biometrics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(9) :1670–1684, Sept 2009.
- [67] D. Hilbert. Ueber die stetige Abbildung einer Line auf ein Flächenstück. *Mathematische Annalen*, 38(3) :459–460, 1891.
- [68] Y. Hu, K. Sirlantzis, and G. Howells. Improving colour iris segmentation using a model selection technique. *Pattern Recognition Letters*, 57 :24 – 32, 2015.
- [69] ICE. Iris Challenge Evaluation. <http://www.nist.gov/itl/iad/ig/ice.cfm>, 2005.
- [70] A. K. Jain, A. Ross, and S. Prabhakar. An Introduction to Biometric Recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1) :4–20, Jan 2004.
- [71] L. R. Kennell, R. W. Ives, and R. M. Gaunt. Binary Morphology and Local Statistics Applied to Iris Segmentation for Recognition. In *Image Processing, 2006 IEEE International Conference on*, pages 293–296. IEEE, 2006.
- [72] O. Koller, O. Zargaran, H. Ney, and R. Bowden. Deep Sign : Hybrid CNN-HMM for Continuous Sign Language Recognition. In *Proceedings of the British Machine Vision Conference 2016*, 2016.
- [73] P. Lanchantin, J. Lapuyade-Lahorgue, and W. Pieczynski. Unsupervised segmentation of triplet Markov chains hidden with long-memory noise. *Signal Processing*, 88(5) :1134–1151, 2008.
- [74] P. Lanchantin and W. Pieczynski. UNSUPERVISED NON STATIONARY IMAGE SEGMENTATION USING TRIPLET MARKOV CHAINS. *Advanced Concepts for Intelligent Vision Systems (ACVIS 04)*, 2004.
- [75] S. Le Cam, F. Salzenstein, and C. Collet. Fuzzy pairwise Markov chain to segment correlated noisy data. *Signal Processing*, 88(10) :2526 – 2541, 2008.

- [76] L.Flom and A.Safir. Iris recognition system, February 3 1987. US Patent 4,641,349.
- [77] S. Z. Li. *Markov Random Field Modeling in Computer Vision*. Springer Science & Business Media, 2012.
- [78] N. Liu, H. Li, M. Zhang, J. Liu, Z. Sun, and T. Tan. Accurate iris segmentation in non-cooperative environments using fully convolutional networks. In *Biometrics (ICB), 2016 International Conference on*, pages 1–8. IEEE, 2016.
- [79] X. Liu, K. W. Bowyer, and P. J. Flynn. Experiments with An Improved Iris Segmentation Algorithm. In *Automatic Identification Advanced Technologies, 2005. Fourth IEEE Workshop on*, pages 118–123. IEEE, 2005.
- [80] L. Ma, T. Tan, Y. Wang, and D. Zhang. Personal identification based on iris texture analysis. *IEEE transactions on pattern analysis and machine intelligence*, 25(12) :1519–1533, 2003.
- [81] J. MacQueen. SOME METHODS FOR CLASSIFICATION CLASSIFICATION AND ANALYSIS OF MULTIVARIATE OBSERVATIONS. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. California, USA, 1967.
- [82] J. Marroquin, S. Mitter, and T. Poggio. Probabilistic Solution of Ill-Posed Problems in Computational Vision. *Journal of the American Statistical Association*, 82(397) :76–89, 1987.
- [83] L Masek. Recognition of Human Iris Patterns for Biometric Identification. 2003.
- [84] G. J. McLachlan and T. Krishnan. Wiley Series in Probability and Statistics. *The EM Algorithm and Extensions, Second Edition*, pages 361–369, 2000.
- [85] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Three-Class Markovian Segmentation of High-Resolution Sonar Images. *Computer Vision and Image Understanding*, 76(3) :191–204, 1999.

- [86] M. Mignotte, C. Collet, P. Perez, and P. Bouthemy. Sonar Image Segmentation Using an Unsupervised Hierarchical MRF Model. *IEEE Transactions on Image Processing*, 9(7) :1216–1231, 2000.
- [87] K. Miyazawaand, K. Ito, T. Aoki, K. Kobayashi, N. Koji, and H.Nakajima. An Effective Approach for Iris Recognition Using Phase-Based Image Matching. *IEEE transactions on pattern analysis and machine intelligence*, 30(10) :1741–1756, 2008.
- [88] E. Monfrini and W. Pieczynski. Estimation de mélanges généralisés dans les arbres de Markov cachés, application à la segmentation des images de cartons d’orgue de barbarie. 2005.
- [89] D. M. Monro, S. Rakshit, and D. Zhang. DCT-Based Iris Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(4), 2007.
- [90] P. R. Nalla and A. Kumar. Toward More Accurate Iris Recognition Using Cross-Spectral Matching. *IEEE Transactions on Image Processing*, 26(1) :208–221, Jan 2017.
- [91] NICE.I. Noisy Iris Challenge Evaluation, Part I. <http://nice1.di.ubi.pt/>, 2008.
- [92] N. Othman, B. Dorizzi, and S. Garcia-Salicetti. OSIRIS : An open source iris recognition software. *Pattern Recognition Letters*, pages –, 2015.
- [93] S. J. K. Pedersen. Circular Hough Transform. *Aalborg University, Vision, Graphics, and Interactive Systems*, 123, 2007.
- [94] L. Peihua, L. Xiaomin, L. Xiao, and Q. Song. Robust and accurate iris segmentation in very noisy iris images. *Image and Vision Computing*, 28(2) :246 – 253, 2010. Segmentation of Visible Wavelength Iris Images Captured At-a-distance and On-the-move.
- [95] P. J. Phillips, A. Martin, C. L. Wilson, and M. Przybocki. An Introduction Evaluating Biometric Systems. *Computer*, 33(2) :56–63, Feb 2000.
- [96] W. Pieczynski. STATISTICAL IMAGE SEGMENTATION. *Machine graphics and vision*, 1(1/2) :261–268, 1992.

- [97] W. Pieczynski. Pairwise Markov Chains. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(5) :634–639, 2003.
- [98] W. Pieczynski. Multisensor triplet Markov chains and theory of evidence. *International Journal of Approximate Reasoning*, 45(1) :1–16, 2007.
- [99] W. Pieczynski. Sur la convergence de l'estimation conditionnelle itérative. *Comptes Rendus Mathématique*, 346(7) :457–460, 2008.
- [100] W. Pieczynski, C. Hulard, and T. Veit. Triplet Markov Chains in hidden signal restoration. In *International Symposium on Remote Sensing*, pages 58–68. International Society for Optics and Photonics, 2003.
- [101] W. Pieczynski and A. N. Tebbache. PAIRWISE MARKOV RANDOM FIELDS AND SEGMENTATION OF TEXTURED IMAGES. *Machine graphics and vision*, 9(3) :705–718, 2000.
- [102] H. Proença and L. Alexandre. UBIRIS : A noisy iris image database. *Image Analysis and Processing-ICIAP 2005*, pages 970–977, 2005.
- [103] H. Proença and L. Alexandre. Iris segmentation methodology for non-cooperative recognition. *IEE Proceedings-Vision, Image and Signal Processing*, 153(2) :199–205, 2006.
- [104] H. Proença and L. Alexandre. Iris recognition : Analysis of the error rates regarding the accuracy of the segmentation stage. *Image and vision computing*, 28(1) :202–206, 2010.
- [105] H. Proença. Iris Recognition : On the Segmentation of Degraded Images Acquired in the Visible Wavelength. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 32(8) :1502–1516, Aug 2010.
- [106] H. Proença, S. Filipe, R. Santos, J. Oliveira, and L. A. Alexandre. The UBIRIS.v2 : A Database of Visible Wavelength Iris Images Captured On-the-Move and At-a-Distance. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 32(8) :1529–1535, Aug 2010.

- [107] S. Pundlik, D. Woodard, and S. Birchfield. Iris segmentation in non-ideal images using graph cuts. *Image and Vision Computing*, 28(12) :1671–1681, 2010.
- [108] W. Qian and D. M. Titterton. On the use of Gibbs Markov chain models in the analysis of images based on second-order pairwise interactive distributions. *Journal of Applied Statistics*, 16(2) :267–281, 1989.
- [109] G. W. Quinn, J. Matey, E. Tabassi, and P. J. Grother. IREX V : Guidance for Iris Image Collection, 2014.
- [110] S. Rafi, M. Castella, and W. Pieczynski. PAIRWISE MARKOV MODEL APPLIED TO UNSUPERVISED IMAGE SEPARATION. In *IASTED International Conference on Signal Processing, Pattern Recognition, and Applications (SPPRA)*, pages 16–18, 2011.
- [111] K.B. Raja, R. Raghavendra, V. K. Vemuri, and C. Busch. Smartphone based visible iris recognition using deep sparse filtering. *Pattern Recognition Letters*, 57 :33 – 42, 2015.
- [112] C. Rathgeb, A. Uhl, and P. Wild. Iris-biometric comparators : Exploiting comparison scores towards an optimal alignment under Gaussian assumption. In *Biometrics (ICB), 2012 5th IAPR International Conference on*, pages 297–302. IEEE, 2012.
- [113] C. Rathgeb, A. Uhl, and P. Wild. *Iris Biometrics : From Segmentation to Template Security*. Springer Publishing Company, Incorporated, 2012.
- [114] C. Rathgeb, A. Uhl, and P. Wild. *The Human Iris as a Biometric Identifier*, pages 3–6. Springer New York, New York, NY, 2013.
- [115] J. Roerdink and A. Meijster. The Watershed Transform : Definitions, Algorithms and Parallelization Strategies. *Fundamenta informaticae*, 41(1, 2) :187–228, 2000.
- [116] A. Ross and S. Shah. Segmenting non-ideal irises using geodesic active contours. In *Biometric Consortium Conference, 2006 Biometrics Symposium : Special Session on Research at the*, pages 1–6. IEEE, 2006.

- [117] K. Roy, P. Bhattacharya, and C. Y. Suen. Towards nonideal iris recognition based on level set method, genetic algorithms and adaptive asymmetrical SVMs. *Engineering Applications of Artificial Intelligence*, 24(3) :458–475, 2011.
- [118] C. Sanchez-Avila, R. Sanchez-Reillo, and D. de Martin-Roche. Iris-based biometric recognition using dyadic wavelet transform. *IEEE Aerospace and Electronic Systems Magazine*, 17(10) :3–6, 2002.
- [119] C. Sanchez-Avila, R. Sanchez-Reillo, and D. de Martin-Roche. Iris-based biometric recognition using dyadic wavelet transform. *IEEE Aerospace and Electronic Systems Magazine*, 17(10) :3–6, 2002.
- [120] W. Sankowski, K. Grabowski, M. Napieralska, M. Zubert, and A. Napieralski. Reliable algorithm for iris segmentation in eye image. *Image and vision computing*, 28(2) :231–237, 2010.
- [121] S. Schuckers, N. Schmid, A. Abhyankar, V. Dorairaj, C. Boyce, and L. Hornak. On Techniques for Angle Compensation in Nonideal Iris Recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 37(5) :1176–1190, 2007.
- [122] S. Shah and A. Ross. Iris Segmentation Using Geodesic Active Contours. *IEEE Transactions on Information Forensics and Security*, 4(4) :824–836, 2009.
- [123] W. Skarbek. Generalized Hilbert scan in image printing. In *Proceedings of the 6th Workshop on Theoretical Foundations of Computer Vision*, page 8. Akademie-Verlag GmbH, 1992.
- [124] S. Song, B. Si, X. Feng, and J. M. Herrmann. Prior parameter estimation for Ising-MRF-based sonar image segmentation by local center-encoding. In *OCEANS 2015-Genova*, pages 1–5. IEEE, 2015.
- [125] G. Sutra, S. Garcia-Salicetti, and D. Dorizzi. The Viterbi Algorithm at Different Resolutions for Enhanced Iris Segmentation. In *Biometrics (ICB), 2012 5th IAPR International Conference on*, pages 310–316. IEEE, 2012.

- [126] R. Szewczyk, K. Grabowski, M. Napieralska, W. Sankowski, M. Zubert, and A. Napieralski. A reliable iris recognition algorithm based on reverse biorthogonal wavelet transform. *Pattern Recognition Letters*, 33(8) :1019–1026, 2012.
- [127] C. W. Tan and A. Kumar. Efficient iris segmentation using Grow-Cut algorithm for remotely acquired iris images. In *Biometrics : Theory, Applications and Systems (BTAS), 2012 IEEE Fifth International Conference on*, pages 99–104, Sept 2012.
- [128] C. W. Tan and A. Kumar. Unified Framework for Automated Iris Segmentation Using Distantly Acquired Face Images. *Image Processing, IEEE Transactions on*, 21(9) :4068–4079, Sept 2012.
- [129] C. W. Tan and A. Kumar. Towards Online Iris and Periocular Recognition Under Relaxed Imaging Constraints. *Image Processing, IEEE Transactions on*, 22(10) :3751–3765, Oct 2013.
- [130] T. Tan, Z. He, and Z. Sun. Efficient and robust segmentation of noisy iris images for non-cooperative iris recognition. *Image and Vision Computing*, 28(2) :223 – 230, 2010. Segmentation of Visible Wavelength Iris Images Captured At-a-distance and On-the-move.
- [131] G. Taubin. Estimation of planar curves, surfaces, and nonplanar space curves defined by implicit equations with applications to edge and range image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(11) :1115–1138, Nov 1991.
- [132] M. Vatsa, R. Singh, and A. Noore. Improving Iris Recognition Performance Using Segmentation, Quality Enhancement, Match Score Fusion, and Indexing. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 38(4) :1021–1035, 2008.
- [133] V. Vezhnevets and V. Konouchine. GrowCut : Interactive Multi-Label N-D Image Segmentation by Cellular Automata. In *proc. of Graphicon*, volume 1, pages 150–156. Citeseer, 2005.

- [134] P. Viola and M. Jones. Robust Real-time Object Detection. In *International Journal of Computer Vision*, 2001.
- [135] P. Viola and M. Jones. Robust Real-Time Face Detection. *International Journal of Computer Vision*, 57(2) :137–154, 2004.
- [136] F. Wang, Y. Wu, Q. Zhang, W. Zhao, M. Li, and G. Liao. Unsupervised SAR Image Segmentation Using Higher Order Neighborhood-Based Triplet Markov Fields Model. *IEEE Transactions on Geoscience and Remote Sensing*, 52(8) :5193–5205, 2014.
- [137] K. Wang and Y. Qian. Fast and accurate iris segmentation based on linear basis function and RANSAC. In *Image Processing (ICIP), 2011 18th IEEE International Conference On*, pages 3205–3208. IEEE, 2011.
- [138] R. P. Wildes. Iris recognition : an emerging biometric technology. *Proceedings of the IEEE*, 85(9) :1348–1363, 1997.
- [139] C. F. J. Wu. On the Convergence Properties of the EM Algorithm. *The Annals of statistics*, pages 95–103, 1983.
- [140] L. Xu, Q. Yan, Y. Xia, and J. Jia. Structure Extraction from Texture via Relative Total Variation. *ACM Transactions on Graphics (TOG)*, 31(6) :139, 2012.
- [141] M. Yahiaoui, E. Monfrini, and B. Dorizzi. Implementation of Unsupervised Statistical Methods for Low-Quality Iris Segmentation. In *Signal-Image Technology and Internet-Based Systems (SITIS), 2014 Tenth International Conference on*, pages 566–573, Nov 2014.
- [142] M. Yahiaoui, E. Monfrini, and B. Dorizzi. Markov Chains for unsupervised segmentation of degraded NIR iris images for person recognition. *Pattern Recogn. Lett.*, 82(P2) :116–123, October 2016.
- [143] P. Zhang, M. Li, Y. Wu, L. Gan, M. Liu, F. Wang, and G. Liu. Unsupervised multi-class segmentation of SAR images using fuzzy triplet Markov fields model. *Pattern Recognition*, 45(11) :4018–4033, 2012.



- [144] Y. Zhang, M. Brady, and S. Smith. Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm. *IEEE transactions on medical imaging*, 20(1) :45–57, 2001.
- [145] Z. Zhao and A. Kumar. An Accurate Iris Segmentation Framework Under Relaxed Imaging Constraints Using Total Variation Model. In *2015 IEEE International Conference on Computer Vision (ICCV)*, pages 3828–3836, Dec 2015.
- [146] J. Zuo, N. Kalka, and N. Schmid. A Robust Iris Segmentation Procedure for Unconstrained Subject Presentation. In *Biometric Consortium Conference, 2006 Biometrics Symposium : Special Session on Research at the*, pages 1–6. IEEE, 2006.

# Table des figures

1.1	Différentes modalités biométriques. . . . .	10
1.2	Exemples d'applications biométriques. . . . .	11
1.3	Acquisition de données avec quelques exemples de capteurs biométriques. . .	12
1.4	Module de reconnaissance d'un système biométrique. . . . .	13
1.5	Densités de scores de dissimilitude d'un système biométrique réel. . . . .	16
1.6	Courbe DET (a) et Courbe ROC (b). . . . .	18
1.7	Vue frontale de l'oeil humain (a) et l'iris humain (b) (1). . . . .	19
1.8	Exemple d'une image de bonne qualité d'un œil acquise dans des conditions contrôlées (109). . . . .	21
1.9	Exemples d'images dégradées d'iris acquise en NIR(109) . . . . .	24
1.10	Exemples d'images dégradées d'iris acquise en lumière visible . . . . .	25
1.11	Exemple de la segmentation d'une image d'iris . . . . .	27
1.12	Illustration de la tâche du module de normalisation d'iris : normalisation (a), transformation rubbersheet (b) (113). . . . .	27
1.13	Génération de l'iris code par le filtre 2D Gabor : une seule échelle (a), différentes échelles (b). . . . .	29
1.14	Comparaison d'iris codes avec translation circulaire (112). . . . .	29
1.15	Exemples d'images de la base ICE2005. . . . .	31
1.16	Exemples d'images de la base CASIA-IrisV4-distance. . . . .	32
1.17	Exemples d'images de la base UBIRIS-v2. . . . .	33

---

2.1	Schéma général d'un système de segmentation de l'iris. . . . .	37
2.2	Détection des contours de l'iris et des paupières par la méthode (145) . . . . .	41
2.3	Illustration de recherche de cercles sur différents contours (125). . . . .	43
2.4	Exemples de mauvaises segmentations résultant de l'application des approches basées sur la recherche de contours. . . . .	47
2.5	Proportions de sclera obtenues à partir des images de l'iris frontales et off-angle (105) . . . . .	49
2.6	Exemples de classification en iris et non iris par apprentissage supervisé (105). . . . .	50
2.7	Extraction des caractéristiques de la sclera de différentes images prises à différentes distances. . . . .	51
2.8	Exemple du regroupement en régions proposé par l'approche (130). . . . .	54
2.9	Version améliorée de l'opérateur IDO basée sur un modèle de constellation (130). . . . .	55
2.10	Exemples de classification grossière en iris et non iris par l'algorithme de marche aléatoire (129). . . . .	56
2.11	Illustration de la segmentation par la méthode (59). . . . .	57
2.12	Exemple d'une image segmentée par l'algorithme Kmeans flou (103). . . . .	58
2.13	Exemple d'une image segmentée en classes par l'algorithme Kmeans basé sur l'histogramme de cooccurrence (94). . . . .	59
2.14	Quelques exemples d'images mal segmentées de l'iris (94) . . . . .	60
2.15	Illustration du regroupement par l'algorithme SLIC (68) . . . . .	61
2.16	Exemples de segmentation par Champs de Markov Caché et minimisation d'énergie par des coupures de graphe (107) . . . . .	62
2.17	Exemples de segmentation par les Champs de Markov Triplets (13). . . . .	63
4.1	Localisation grossière de l'iris . . . . .	92
4.2	Schéma général de la segmentation non supervisée. . . . .	93
4.3	Construction du parcours Hilbert-Peano (3) . . . . .	95
4.4	Construction du <i>parcours Escargot</i> . . . . .	96

---

4.5	Exemples de transformation d'une image de l'iris segmentée en régions en une chaîne. . . . .	97
4.6	La transition des classes dans la chaîne extraite. . . . .	99
4.7	Segmentation d'images dégradées de l'iris (ICE-2005) par les modélisations basées sur le modèle HMC . . . . .	101
4.8	Segmentation d'images dégradées de l'iris (ICE-2005) par les modélisations basées sur le modèle PMC . . . . .	102
4.9	Segmentation des images dégradées de l'iris (ICE-2005) par les modélisations basées sur le modèle TMC . . . . .	103
4.10	Segmentation d'images dégradées de l'iris (ICE-2005) par les modélisations basées sur les modèles TMC et TMC-SOP (Triplet Markov Chain with One Stationarity of Pupil noise) . . . . .	104
4.11	Les erreurs de segmentation E produites par les différentes modélisations. . .	108
4.12	Comparaison des segmentations des images dégradées de l'iris (ICE-2005) par les modèles HMC_SK et HMC_SH. . . . .	114
4.13	Comparaison des segmentations des images dégradées de l'iris (ICE-2005) par les modèles PMC_SK et PMC_SH. . . . .	115
4.14	Comparaison d'segmentations des images dégradées de l'iris (ICE-2005) par les modèles TMC-OSP_SK et TMS-OSP_SH. . . . .	116
5.1	Organigramme du système proposé pour la reconnaissance de l'iris . . . . .	121
5.2	Exemple de mauvaises détections de la pupille par OSIRIS-V4. . . . .	123
5.3	Localisation de la pupille basée sur les projections cumulées. . . . .	124
5.4	Exemple de bonnes détections de la pupille sur les mêmes images que celles présentées dans la figure 5.2 . . . . .	125
5.5	Cercles estimés par OSIRIS-V4 sur l'image de classes. . . . .	126
5.6	Masque de l'iris résultant du module de segmentation d'OSIRIS-V4 . . . . .	127
5.7	Masques non précis de l'iris résultants du module de segmentation d'OSIRIS-V4	127
5.8	Exemples de mauvaises initialisations par histogramme. . . . .	129

5.9	Organigrammes de différents systèmes de reconnaissance de l'iris utilisés dans ce travail. . . . .	132
5.10	Comparaison des performances des systèmes proposés dans cette thèse et OSIRIS-V4 sur la base CASIA-IrisV4-distance (courbe ROC). . . . .	134
5.11	Illustration du sous-échantillonnage de la chaîne . . . . .	139
6.1	Des images dégradées de l'iris prises en lumière visible et NIR avec une totale correspondance des pixels(90) . . . . .	142
6.2	Schéma général de traitement des images en couleur. . . . .	149
6.3	Segmentation d'une image de l'iris de couleur sombre par le modèle HMC_SN. . . . .	150
6.4	Segmentation d'une image de l'iris de couleur claire par le modèle HMC_SN. . . . .	151
6.5	Segmentation d'une image de l'iris de couleur sombre par les modèle HMC_SN et HMC_SN vectoriel . . . . .	152
6.6	Segmentation d'une image de l'iris de couleur claire par les modèles HMC_SN et HMC_SN vectoriel. . . . .	153
6.7	Organigramme des différentes modules de segmentations. . . . .	154

# Liste des tableaux

1.1	Comparaison des caractéristiques des bases de données . . . . .	34
2.1	Méthodes récentes de segmentation de l’iris basées sur la recherche de contours	44
2.2	Nombre d’images et nombre de sujets employés dans les ensembles d’appren- tissage et de test par différentes bases et différents travaux dans la littérature.	53
2.3	Méthodes récentes de segmentation de l’iris basées sur la recherche de régions	64
4.1	Erreurs de segmentation moyennes produites par kmeans et les modèles HMC_PK et HMC_SK. . . . .	109
4.2	Erreurs de segmentation moyennes produites par kmeans et les modèles PMC_PK et PMC_SK. . . . .	109
4.3	Erreurs de segmentation moyennes produites par kmeans et les modèles TMC_PK et TMC_SK. . . . .	109
4.4	Erreurs de segmentation moyennes produites par l’initialisation Histogramme et les modèles HMC_SH et HMC_SK. . . . .	117
4.5	Erreurs de segmentation moyennes produites par l’initialisation Histogramme et les modèles PMC_SH et PMC_SK. . . . .	117
4.6	Erreurs de segmentation moyennes produites par l’initialisation Histogramme et les modèles TMC_SH et TMC_SK. . . . .	117
5.1	Comparaison de performances des systèmes proposés avec d’autres systèmes proposés dans la littérature sur la base CASIA-IrisV4-distance. . . . .	133

5.2	Comparaison des performances des systèmes proposés dans cette thèse et d'OSIRIS-V4 sur la base ICE-2005. . . . .	134
5.3	Temps moyen de traitement. . . . .	136
5.4	Performances et gains de temps correspondant à différentes échelles de sous échantillonnage de l'image originale. . . . .	138
5.5	Performances et gains de temps correspondant à différents pas de sous échantillonnage de la chaîne originale. . . . .	139
6.1	Erreurs de segmentation moyennes $\bar{E}$ de quelques travaux de la littérature récents testés sur les ensembles du test NICE-I et NICE-II. . . . .	147
6.2	Erreurs de segmentation moyennes $\bar{E}$ produites par le modèle HMC_SN sur l'ensemble du test NICE-I. . . . .	151
6.3	Erreurs de segmentation moyennes $\bar{E}$ produites par le modèle HMC_SN vectoriel sur l'ensemble du test NICE-I. . . . .	153
6.4	Erreurs de segmentation moyennes $\bar{E}$ produites par le modèle HMC_SN sur l'ensemble de test NICE-I. . . . .	155

## Résumé

---

L'IRIS est considérée comme une des modalités les plus robustes et les plus performantes en biométrie à cause de ses faibles taux d'erreurs. Ces performances ont été observées dans des situations contrôlées, qui imposent des contraintes lors de l'acquisition pour l'obtention d'images de bonne qualité. Relâcher ces contraintes, au moins partiellement, implique des dégradations de la qualité des images acquises et par conséquent une réduction des performances de ces systèmes. Une des principales solutions proposées dans la littérature pour remédier à ces limites est d'améliorer l'étape de segmentation de l'iris. L'objectif principal de ce travail de thèse a été de proposer des méthodes originales pour la segmentation des images dégradées de l'iris. Les chaînes de Markov ont été déjà proposées dans la littérature pour résoudre des problèmes de segmentation d'images. Dans

ce cadre, une étude de faisabilité d'une segmentation non supervisée des images dégradées d'iris en régions par les chaînes de Markov a été réalisée, en vue d'une future application en temps réel. Différentes transformations de l'image et différentes méthodes de segmentation grossière pour l'initialisation des paramètres ont été étudiées et comparées. Les modélisations optimales ont été introduites dans un système de reconnaissance de l'iris (avec des images en niveaux de gris) afin de produire une comparaison avec les méthodes existantes. Finalement une extension de la modélisation basée sur les chaînes de Markov cachées, pour une segmentation non supervisée des images d'iris acquises en visible, a été mise en place.

**Mots-clés :** Segmentation non supervisée, segmentation de l'iris, chaînes de Markov cachées, couples et triplets, apprentissage, perceptron multi-couche, linéarisation de l'image.

---

## Abstract

---

IRIS is considered as one of the most robust and efficient modalities in biometrics because of its low error rates. These performances were observed in controlled situations, which impose constraints during the acquisition in order to obtain good quality images. The renouncement of these constraints, at least partially, implies degradations in the quality of the acquired images and it is therefore a degradation of these systems' performances. One of the main proposed solutions in the literature to take into account these limits is to propose a robust approach for iris segmentation. The main objective of this thesis is to propose original methods for the segmentation of degraded images of the iris. Markov chains have been well solicited to solve image segmentation problems. In this context, a feasibility study of unsupervised segmentation into regions of degraded iris images by Markov chains was performed. Different image transformations and different segmentation methods for parameters initialization have been studied and compared. Optimal modeling has been inserted in iris recognition system (with grayscale images) to produce a comparison with the existing methods. Finally,



an extension of the modeling based on the hidden Markov chains has been developed in order to realize an unsupervised segmentation of the iris images acquired in visible light.

**Keywords :** Unsupervised segmentation, iris segmentation, Hidden Markov Chains, Pairwise Markov Chains, Triplet Markov Chains ,learning, multilayer perceptron, image linearization.

---