

République Algérienne Démocratique et Populaire
Université Abou Bakr Belkaid– Tlemcen
Faculté des Sciences
Département d'Informatique

Mémoire de fin d'études

Pour l'obtention du diplôme de Master en Informatique

Option : Modèles d'intelligence et de données(MID)

Thème

Segmentation d'image 2D basée sur le modèle de mélange gaussien.

Réalisé par :

- Chenafi Imad Eddine

Présenté le 23/06/2024 devant le jury composé de MM.

- Meziane Tani Souad (Président)
- Benziane Mohamed Yaghmouracene (Encadreur)
- Benaissa Mohammed. (Examineur)

Remerciements

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Je tiens tout d'abord à remercier Mr Benziane Mohammed yaghmouracen mon encadreur de mémoire, pour son encadrement, son suivi et ses conseils lors de la réalisation de mon mémoire.

Je tiens ensuite à remercier tous mes professeurs et enseignants de département d'informatique qui ont contribué à notre formation.

Je souhaite aussi remercier mesdames et messieurs les membres du jury pour leur précieux temps accordé à l'étude de mon mémoire.

Enfin je remercie tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.

Dédicaces

Je dédie cette mémoire :

A mes chers parents et frères pour leur soutien et leurs encouragements tout au long de mes années d'études, sans qui je n'aurais pas réussi.

A tous mes professeurs et professeurs qui m'ont accompagné tout au long de mon parcours scolaire et qui m'ont permis de réussir mes études.

À mon meilleur amie Benameur Fatíha et à mon ami Boudghen Stambouli Mohammed et à tous mes amis à l'université et en dehors, et à tous ceux qui ont contribué directement ou indirectement à ce travail.

Résumé

Dans ce mémoire, nous proposons une méthode de segmentation d'images 2D basée sur le modèle de mélanges gaussien (GMM). Les paramètres du mélange sont estimés par l'algorithme Espérance Maximisation (EM). Un critère de mesure d'uniformité de région est utilisé pour comparer les performances du modèle proposé par rapport au modèle de mélanges de gaussiennes (GMM) avec résolution. Les résultats expérimentaux confirment l'efficacité du modèle proposé.

Mots clés : segmentation d'image, le modèle mélange gaussien (GMM), algorithme EM (Expectation-Maximisation), cluster.

Abstract

In this dissertation, we propose a 2D image segmentation method based on the Gaussian mixture model (GMM). The Expectation Maximization (EM) algorithm estimates the mixture parameters. A region uniformity measurement criterion is used to compare the performance of the proposed model against the Gaussian mixture model (GMM) with resolution. The experimental results confirm the effectiveness of the proposed model.

Key words: image segmentation, Gaussian mixture model (GMM), EM (Expectation-Maximization) algorithm, cluster.

ملخص

في هذه الأطروحة، نقترح طريقة تجزئة الصور ثنائية الأبعاد على أساس نموذج الخليط الغوسي (GMM). يتم تقدير معلمات الخليط بواسطة خوارزمية تعظيم التوقعات (EM). يتم استخدام معيار قياس توحيد المنطقة لمقارنة أداء النموذج المقترح مع نموذج الخليط الغوسي (GMM) مع الدقة. وتؤكد النتائج التجريبية فعالية النموذج المقترح.

الكلمات المفتاحية: تجزئة الصورة، نموذج الخليط الغوسي (GMM)، خوارزمية EM (التوقع-التعظيم)، الكتلة.

Sommaire

Sommaire

Introduction générale.....	1
----------------------------	---

Chapitre 01 : image et segmentation

1.1.Introduction.....	4
1.2.Définition d'une image.....	4
1.3.Image numérique.....	4
1.4.Types d'image.....	5
1.5.Les filtres.....	6
1.5.1 Les filtres linéaires.....	6.
1.5.1.1. Filtre moyenne.....	6
1.5.1.2. Filtre gaussien.....	7
1.5.1.3. Filtre laplacien.....	7
1.5.2 Les filtres non linéaires.....	8
1.5.2.1. Filtre médian.....	8
1.6.Caractéristiques d'une image numérique.....	8
1.6.1 Pixel.....	8
1.6.2 La résolution.....	9
1.6.3 La dimension.....	9
1.6.4 La texture.....	9
1.6.5 Bruit.....	10
1.6.6 La luminance.....	10
1.6.7 Contours et textures.....	10
1.6.8 Histogramme.....	10
1.6.9 Le constrate.....	10
1.7.Définition de la segmentation d'images.....	11
1.8.Objectifs de la segmentation.....	12
1.9.Méthodes de segmentation d'images.....	12
1.9.1 segmentation par seuillage	12
1.9.2 segmentation par croissance de région.....	12
1.9.3 segmentation par détection de contours.....	13
1.9.4 segmentation par classification.....	13
1.10. domaines d'application de la segmentation d'images.....	14
1.11. Les types de segmentation d'image.....	14
1.12. Conclusion.....	15

Chapitre 02 : modèle mélange gaussien

2.1.Introduction.....	17
2.2.définition de modèle mélange gaussien.....	17
2.3.formules de modèle mélange gaussien.....	19
2.4.la méthode EM (Expectation-Maximisation) du modèle mélange gaussien	20
2.5.Algorithme de la méthode GMM.....	23
2.6.Quelques méthodes sur la méthode GMM.....	24
2.7.Conclusion.....	26

Chapitre 03 : Implémentation et résultats

3.1.Introduction.....	28
3.2.Matériel utilisée.....	28
3.3.Description des données.....	28
3.4.Implémentation du modèle mélange gaussien.....	31
3.5.Validation et évaluation.....	33
3.6.Résultats de la segmentation.....	33
3.7.Analyse des résultats.....	33
3.8.Comparaisons avec d'autres méthodes.....	37
3.8.1. Segmentation d'image basée sur mélange gaussien avec résolution :.....	37
3.8.2. Manuelle.....	43
3.8.3. Comparaison.....	43
3.9.Conclusion.....	44
Conclusion générale.....	45
Bibliographie.....	48

Liste des figures

Figure01 : Représentation d'image numérique.....	4
Figure02 : groupe pixel formant la lettre A.....	8
Figure03 : modèle mélange gaussien expliquée.....	17
Figure04 : image brain_b.....	29
Figure05 : image brain_2.....	29
Figure06 : image knee.....	30
Figure07 : image meningima.....	30
Figure08 : organigramme de l'implémentation du modèle GMM.....	32
Figure09 : l'image meningima segmentée par GMM.....	34
Figure10 : l'image brain_2 segmentée par GMM.....	35
Figure11 : l'image brain_b segmentée par GMM.....	35
Figure12 : l'image knee segmentée par GMM.....	35
Figure13 : image meningioma avec la résolution 1/2, 1/3 et 1/4.....	37
Figure14 : image brain_2 avec la résolution 1/2, 1/3 et 1/4.....	37
Figure15 : image brain_b avec la résolution 1/2, 1/3 et 1/4.....	38
Figure16 : image knee avec la résolution 1/2, 1/3 et 1/4.....	38
Figure17 : image meningioma segmentée avec et sans résolution.....	39
Figure18 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image meningioma.....	39
Figure19 : image brain_2 segmentée avec et sans résolution.....	40
Figure20 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image brain_2.....	40
Figure21 : image brain_b segmentée avec et sans résolution.....	41

Figure22 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image brain_b.....41

Figure23 : image knee segmentée avec et sans résolution.....42

Figure24 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image knee.....42

Figure 25 : tableau montre la différence entre GMM et GMM avec résolution...43

Introduction générale

Introduction générale

La segmentation d'image est un problème important dans le domaine de l'analyse d'image. Elle est, par exemple, utilisée en imagerie médicale afin d'analyser et de quantifier les différentes structures anatomiques présentes dans les images. L'intérêt de la segmentation est de partitionner une image en plusieurs régions homogènes, au sens d'un critère fixé a priori. L'intérêt de disposer de régions homogènes est de fournir des données simplifiées qui facilitent la tâche d'un système de reconnaissance de formes, ou autre système d'extraction des objets contenus dans l'image.

Le mélange gaussien est une approche populaire pour la segmentation d'images en raison de sa capacité à modéliser des distributions de pixels complexes et à identifier des clusters dans des données multimodales. Pourquoi le mélange gaussien est une bonne approche pour la segmentation d'images ? Quels défis adresse-t-il ?

L'objectif de ce travail vise à explorer en profondeur la méthode de segmentation d'image basée sur le mélange gaussien, en examinant ses principes théoriques, ses avantages, ses limitations et ses applications potentielles. Le travail inclut une évaluation comparative de la méthode de segmentation d'image basée sur le mélange gaussien par rapport à d'autres méthodes de segmentation par exemple segmentation d'image basée sur le mélange gaussien avec résolution, en termes de précision, de robustesse, de temps de calcul, etc.

Cette étude s'articule autour de trois chapitres qui nous permettront de présenter les différents aspects de notre travail. Le premier présente l'image et la segmentation d'image en générale. Puis, dans le deuxième chapitre, j'ai présenté le modèle de mélange gaussien en général. Le troisième chapitre est la partie expérimentations et résultats obtenus où nous montrons l'apport de gaussien mixture model (GMM) de la segmentation d'image. Nous terminons ce travail par une conclusion générale et perspective.

Chapitre 01 :
Image et Segmentation

1.1. Introduction

La segmentation d'images est l'un des problèmes les plus anciens et les plus étudiés en vision par ordinateur. Elle consiste à diviser une image en un groupe de groupes de pixels appelés régions. Chaque région a ses propres caractéristiques. Dans ce chapitre, nous expliquons ce qu'est une image, ses caractéristiques, qu'est-ce que la segmentation d'image et quelques méthodes de segmenter une image. Nous parlerons également de quelques cas d'utilisation de la segmentation d'image.

1.2. Définition d'une image

L'image est une représentation d'une personne ou d'un objet par la peinture, le dessin, la photographie, le film, etc..... C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, ont une signification pour l'œil humain. Elle peut être décrite sous la forme d'une fonction $I(x, y)$ analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation. [5]

1.3. Image numérique (numérisée) :

L'image numérique est l'image dont la surface est divisée en éléments de taille fixe appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs. [5]

La numérisation d'une image est la conversion de celle-ci de son état analogique en une image numérique représentée par une matrice bidimensionnelle de valeurs numériques $f(x,y)$, comme la montre la figure où :

x, y : coordonnées cartésiennes d'un point de l'image.

$F(x, y)$: niveau d'intensité.

La valeur en chaque point exprime la mesure d'intensité lumineuse perçue par le capteur.




Figure01 : Représentation d'image numérique.

1.4. Types d'image :

Image binaire

Une image binaire est une image $M \times N$ où chaque point peut prendre uniquement la valeur 0 ou 1. Les pixels sont noirs (0) ou blancs (1). Le niveau de gris est codé sur un bit (Binary digit). Dans ce cas avec $N_g = 2$ et la relation sur les niveaux de gris devient : $p(i,j) = 0$ ou $p(i,j) = 1$ [7].

Image en niveaux de gris

Une image en niveaux de gris autorise un dégradé de gris entre le noir et le blanc. En général, on code le niveau de gris sur un octet (8 bits) soit 256 nuances de dégradé. L'expression de la valeur du niveau de gris avec $N_g = 256$ devient : $p(i,j) \in [0, 255]$ [7].

Image couleur

Une image couleur est la composition de trois (ou plus) images en niveaux de gris sur trois (ou plus) composantes. On définit donc trois plans de niveaux de gris, un rouge, un vert et un bleu. La couleur finale est obtenue par synthèse additive des ces trois (ou plus) composantes [7].

Chapitre 01 : image et segmentation

. Image à valeurs réelles

Pour certains calculs sur les images, le résultat peut ne pas être entier, il est donc préférable de définir l'image de départ et l'image résultat comme des images à valeurs réelles. En général, une image à valeurs réelle est telle que le niveau de gris est un réel compris entre 0.0 et 1.0. On a dans ce cas pour une image à niveaux de gris : $p(i,j) \in [0.0, 1.0]$. Pour une image couleur, la relation devient $p_R(i,j) \in [0.0, 1.0]$, $p_V(i,j) \in [0.0, 1.0]$, $p_B(i,j) \in [0.0, 1.0]$ [7].

1.5. Les filtres :

Les filtrages visent à modifier le contenu d'un pixel en prenant en compte une information locale, c'est-à-dire une information extraite du voisinage plus ou moins étendu du pixel. D'une façon générale, le filtrage est obtenu par convolution de l'image avec un noyau défini. Ce noyau peut être interprété comme une petite image ou vignette contenant un gabarit de transformation (linéaire ou non linéaire) et que l'on applique sur chacun des pixels de l'image à filtrer pour créer une nouvelle image [14].

1.5.1. Filtres linéaires :

Les filtres linéaires transforment un ensemble de données d'entrée en un ensemble de données de sortie par une convolution bidimensionnelle qui est une opération mathématique. Ils permettent de supprimer le bruit dans l'image. Chaque filtre a une taille $N \times N$ avec N impair. Parmi les filtres linéaires les plus utilisés on trouve [16] :

1.5.1.1. Filtre moyenne

Il Permet de lisser l'image (smoothing) et remplace chaque pixel par la valeur moyenne de ses voisins et réduire le bruit et les détails non-important [23].

Le filtre moyenne permet de :

- *Permet de lisser l'image (smoothing)*
- *Remplace chaque pixel par la valeur moyenne de ses voisins*
- *Réduit le bruit o Réduit les détails non-important*
- *Brouille ou rend floue l'image (blur edges)*

Chapitre 01 : image et segmentation

1.5.1.2. Filtre gaussien

Le filtre gaussien donnera un meilleur lissage et une meilleure réduction du bruit que le filtre moyenne. [23]

L'intérêt de ce filtre est que l'on contrôle facilement le degré de filtrage à travers le paramètre σ . Le filtre gaussien donne plus d'importance aux pixels proches du pixel central, et diminue cette importance au fur et à mesure que l'on s'éloigne de celui-ci, il a les mêmes inconvénients que le filtre passe-bas, c'est-à-dire il dégrade les contours.

La discrétisation de ce filtre pour un σ égale à 0.6 donne les masques suivants [1] :

1/16*

1	2	1
2	4	2
1	2	1

1/246*

1	4	6	4	1
4	16	24	16	4
6	24	36	24	6
4	16	24	16	4
1	4	6	4	1

L'expression gaussienne en deux dimensions est donnée par :

$$G_0(x, y) = \frac{1}{2\pi \sigma^2} * \exp\left(\frac{-x^2 + y^2}{2 \sigma^2}\right)$$

1.5.1.3. Filtre laplacien :

Le filtre Laplacien permet la détection de contours. Un contour est défini comme une discontinuité locale de l'intensité lumineuse [30].

On peut trouver différents opérateurs Laplaciens [31] :

Laplacien 4-connexe :

0	1	0
1	-4	1
0	1	0

1.5.2. Filtres non linéaires :

Pour éviter le flou introduit par les filtres passe-bas classiques, une autre famille de méthodes existe, les filtres non linéaires ou filtres d'ordre. Ce sont des filtres dans lesquels la nouvelle valeur du pixel est calculée par une combinaison non linéaire de la fenêtre des pixels avoisinants [16].

Le filtre médian est le filtre non linéaire le plus utilisé :

1.5.2.1. Filtre médian

Il supprime le bruit dans l'image. Son algorithme est relativement simple, le filtre remplace la valeur de chaque pixel par la valeur médiane du pixel et de ses voisins. Le nombre de voisins peut être déterminé à l'aide d'un paramètre 'N'. Ce paramètre indique la taille du carré dans lequel seront effectués les calculs [17].

1.6. Caractéristiques d'une image numérique :

Comme nous l'avons vu, l'image est un ensemble structuré d'informations parmi ses caractéristiques nous pouvons citer les paramètres suivants :

1.6.1. Pixel :

Contraction de l'expression anglaise " Picture Elements " : éléments d'image, le pixel est le plus petit point de l'image, c'est une valeur numérique représentative des intensités lumineuses.

Si le bit est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que peuvent manipuler les matériels et logiciels sur l'image. La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous [3].




Figure02 : groupe de pixel formant la lettre A.

1.6.2. La résolution :

La résolution d'une image numérique est le niveau de détail qu'elle contient. Elle est définie par le nombre de pixels qui composent l'image, et s'exprime généralement en points par pouce (PPP) ou dots per inch (DPI).

Plus le nombre de pixels par pouce est élevé, plus l'image est riche en détails et donc de meilleure qualité. [4]

1.6.3. La dimension

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image.[4]

1.6.4. La texture

Une texture est une région dans une image numérique qui a des caractéristiques homogènes. Ces caractéristiques sont par exemple un motif basique qui se répète .la texture est composée de Texel, l'équivalent des pixels.[6]

Chapitre 01 : image et segmentation

1.6.5. Bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur.[2]

1.6.6. La luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet. [1]

1.6.7. Contours et textures

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes. [6]

1.6.8. Histogramme

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image.

Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. [5]

1.6.9. Le contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. [2]

1.7. Définition de la segmentation d'images

La segmentation d'image est le processus de division d'une image numérique en plusieurs parties, régions ou différentes catégories en fonction de critères tels que la densité de pixels ou la résolution spatiale, dans le but de simplifier ou de modifier la représentation de l'image pour la rendre plus significative et plus facile à visualiser et analyser. Cela permet de créer des zones uniformes dans l'image, facilitant ainsi la détection des objets et leur distinction de l'arrière-plan. La segmentation d'images est essentielle pour des tâches telles que la reconnaissance d'objets et la détection de contours. De plus, la réduction du bruit et le débruitage constituent un aspect important du traitement d'image classique, et il existe de nombreuses façons d'y parvenir. [7]

Formellement, la segmentation d'une image A en régions R_i , $i = 1..n$, est définie par les propriétés suivantes : [8]

$$U_{i=1}^n R_i = I$$

$$R_i \cap R_j = \emptyset \quad \forall i, j \text{ telle que } i \neq j$$

$$P(R_i) = \text{vrai} ; \forall i \in \{1, 2, \dots, n\}$$

$$R_i \text{ est un composant connexe ; } \forall i \in \{1, 2, \dots, n\}$$

P est un prédicat d'homogénéité.

La première condition indique que l'union des régions nous ramène à l'image de départ.

La deuxième indique que deux régions différentes sont disjointes.

La troisième exprime que les pixels appartenant à une région doivent satisfaire le critère d'homogénéité.

La quatrième exprime le critère d'homogénéité pour la segmentation en régions disjointes.

1.8. Objectifs de la segmentation :

Ils permettent de [13] :

- *Fournir des régions homogènes.*
- *Extraire les entités d'une image.*
- *Pour y applique un traitement spécifique.*
- *Pour interpréter le contenu d'une image.*
- *Localiser de manière précise les contours des régions.*
- *L'étude et l'interprétation des structures anatomiques.*
- *Réduction de bruit.*

1.9. Méthodes de segmentation d'images :

1.9.1 Segmentation par seuillage :

La segmentation par seuillage est l'opération qui associe à chaque point de l'image $I(i,j)$ une classe de luminance (étiquette e_l , $l=1, \dots, C$) après comparaison de ses attributs (niveaux de gris) à un ou plusieurs seuils qui peuvent être déterminés globalement ou localement. Une (ou plusieurs) valeur de seuil optimal est recherchée en se basant sur certains critères [20].

Cette méthode est la plus simple de segmentation d'image. À partir d'une image en niveau de gris, le seuillage d'image peut être utilisé pour créer une image comportant uniquement deux valeurs, noir ou blanc (monochrome).

1.9.2 Segmentation par la croissance de régions :

Cette approche consiste à explorer l'image à partir de regroupements initiaux de pixels connexes appelés germes, et à faire croître ceux-ci sous une double contrainte d'adjacence et d'homogénéité. Les germes sont sélectionnés de manière déterministe ou aléatoire par prétraitement de l'image. De manière itérative, de nouveaux pixels sont ajoutés aux germes jusqu'à ce que la région en cours de construction ne respecte plus le ou les prédicats mis en place. La plupart de ces algorithmes parcourent l'image selon un ordre qui peut influencer le résultat de la segmentation. Le parcours le plus fréquent consiste à partir d'un germe en haut à gauche de l'image pour se diriger vers le bas à droite de l'image [12].

L'avantage de cette approche est de préserver la forme de chaque région de l'image. Cependant, une mauvaise sélection des germes ou un choix du prédicat mal adapté

Chapitre 01 : image et segmentation

peuvent entraîner des phénomènes de sous-segmentation ou de sur-segmentation [11].

1.9.3 Segmentation par la détection de contours :

La détermination des limites des objets est un sujet de recherche très important. Les approches liées à cette catégorie recherchent des discontinuités des intensités lumineuses où les contours se manifestent dans l'image par une forte transition des valeurs de ces intensités. Deux catégories existent, celles qui emploient le filtrage différentiel ou adaptatif (tels que les points de fort gradient) et celles qui utilisent les outils de la programmation dynamique tels que la morphologie mathématique ou les approches probabilistes [18] [19].

Cette méthode détecte les contours ou les frontières dans une image en identifiant les transitions abruptes d'intensité ou de couleur entre les pixels. Les contours sont ensuite utilisés pour diviser l'image en régions.

1.9.4 Segmentation par la classification :

La segmentation d'images basée sur la classification est une technique qui consiste à diviser une image en régions ou segments homogènes en fonction de certaines caractéristiques, souvent après avoir classifié les différents éléments de l'image.

Ces méthodes déterminent d'abord une partition de l'espace des luminances en utilisant les niveaux de gris présents dans l'image. On associe à chaque pixel la classe de niveaux de gris à laquelle il appartient. Les régions sont définies par les ensembles maximaux de pixels connexes appartenant à la même classe [24]. Les classes sont construites à partir des attributs des pixels. Chaque pixel est affecté à une classe unique, mais il est classifié indépendamment de ses voisins. Les critères de proximité employés sont en effet, des distances entre vecteur d'attributs et ne tiennent pas compte de la proximité entre pixels dans l'image [25].

1.10. Domaines d'application de la segmentation d'images :

- **Imagerie médicale** : dans La médecine, la segmentation est utilisée pour séparer les différents organes et tissus dans les images médicales, ce qui permet une meilleure analyse et une meilleure prise de décision pour les diagnostics et les traitements [26].
- **La robotique** : la segmentation est utilisée pour séparer les objets et les régions d'intérêt dans les images de la caméra du robot, ce qui facilite la navigation autonome et la manipulation d'objets [26].
- **La surveillance vidéo** : La segmentation est utilisée pour détecter les mouvements et les objets dans les images de caméra de surveillance, ce qui permet une meilleure surveillance et une meilleure détection des intrusions [26].
- **La vision industrielle** : La segmentation est utilisée pour séparer les objets et les régions d'intérêt dans les images prises par les caméras industrielles, ce qui facilite la surveillance et la maintenance des processus industriels [26].
- **La reconnaissance d'objets** : La segmentation est utilisée pour séparer les objets d'arrière-plan dans une image, ce qui facilite la reconnaissance d'objets [26].

1.11. Les types de segmentation d'image :

Parmi les différentes méthodes de segmentation, nous pouvons distinguer celles basées sur des techniques particulières :

- **La segmentation basée sur les propriétés statistiques de l'image** : ces méthodes utilisent des caractéristiques statistiques de l'image telles que la moyenne, la variance, etc. pour séparer les différentes régions de l'image. Ces méthodes sont souvent simples et rapides à mettre en œuvre, mais elles peuvent être sensibles aux variations de luminosité et de couleur dans l'image [26].
- **La segmentation basée sur les propriétés géométriques de l'image** : ces méthodes utilisent des caractéristiques géométriques telles que les contours, les coins, etc. pour séparer les différentes régions de l'image. Ces méthodes sont souvent plus robustes aux variations de luminosité et de couleur, mais elles peuvent être plus difficiles à mettre en œuvre et plus sensibles aux perturbations de l'image [26].

Chapitre 01 : image et segmentation

- **La segmentation basée sur les réseaux de neurones** : ces méthodes utilisent des réseaux de neurones pour apprendre les caractéristiques des images et pour séparer les différentes régions de l'image. Ces méthodes peuvent être très efficaces pour les applications de reconnaissance d'objets, mais elles peuvent nécessiter beaucoup de données d'entraînement et de puissance de calcul [26].
- **La segmentation basée sur les modèles physiques** : ces méthodes utilisent des modèles physiques pour décrire les processus de génération de l'image et pour séparer les différentes régions de l'image. Ces méthodes peuvent être très efficaces pour les applications de traitement d'images médicales et de surveillance vidéo, mais elles peuvent être difficiles à mettre en œuvre et nécessiter des connaissances approfondies en physique [26].

1.12. Conclusion

Dans ce chapitre, on a essayé de regrouper les techniques de segmentation d'images en quatre méthodes : une méthode basée sur le seuil, une méthode basée sur la région de croissance, une méthode basée sur la détection des contours et une méthode basée sur la classification. Bien qu'ils présentent tous des avantages, ils présentent également de nombreux inconvénients. Puisque la segmentation d'images peut être considérée comme un problème d'optimisation, dans le prochain chapitre, j'introduirai différentes segmentations d'images par modèle de mélange gaussien (GMM).

Chapitre 2 :
Le modèle de mélange
gaussien

2.1. Introduction

Nous savons dans le chapitre précédent qu'il existe de nombreuses façons de segmenter une image. Dans ce chapitre, nous parlerons du modèle de mélange Gaussien. C'est une méthode d'apprentissage automatique de clustering souple utilisée pour déterminer la probabilité que chaque point de données appartienne à un cluster donné. Le modèle est une méthode de clustering souple utilisée dans l'apprentissage non supervisé.

2.2. Définition du modèle de mélange gaussien :

Un mélange gaussien est une fonction composée de plusieurs gaussiennes, chacune identifiée par $k \in \{1, \dots, K\}$, où K est le nombre de clusters de notre ensemble de données. Chaque k gaussien du mélange est composé des paramètres suivants : **[9]** Le modèle de mélange de gaussiennes fait partie des méthodes de classification paramétrique globale. Il consiste à supposer que la distribution des données peut être décrite comme une somme pondérée de densités gaussiennes. Chaque gaussienne du modèle est caractérisée par son poids, son vecteur moyenne et sa matrice de covariance [27].

Un μ moyen qui définit son centre.

Une covariance Σ qui définit sa largeur. Cela équivaldrait aux dimensions d'un ellipsoïde dans un scénario multi varié.

Une probabilité de mélange π qui définit la taille de la fonction gaussienne.

Illustrons ces paramètres graphiquement :




Figure03 : modèle mélange gaussien expliqué

Chapitre 02 : le modèle de mélange gaussien

Il existe trois fonctions gaussiennes, donc $k = 3$. Chaque gaussienne explique les données contenues dans chacun des trois clusters disponibles. Les coefficients de mélange sont eux-mêmes des probabilités et doivent remplir cette condition :

$$\sum_{k=1}^K \pi_k = 1 \quad (1)$$

En général, la fonction de densité gaussienne est donnée par :

$$\mathcal{N}(\mathbf{x}|\mu, \Sigma) = \frac{1}{(2\pi)^{D/2}|\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1}(\mathbf{x} - \mu)\right) \quad (2)$$

$\mathbf{x}$ représente nos points de données,

D est le nombre de dimensions de chaque point de données.

π_k P_i est le poids de la k -eme composante. **[15]**

$$P_i = \frac{1}{n} \sum_{i=1}^n p(i|\mathbf{x}_i, \lambda) \quad (3)$$

μ est la moyenne. **[15]**

$$\mu_i = \frac{\sum_{i=1}^n p(i|\mathbf{x}_i, \lambda) \mathbf{x}_i}{\sum_{i=1}^n p(i|\mathbf{x}_i, \lambda)} \quad (4)$$

σ est la variance. **[15]**

$$\sigma_i^2 = \frac{\sum_{i=1}^n p(i|\mathbf{x}_i, \lambda) \mathbf{x}_i^2}{\sum_{i=1}^n p(i|\mathbf{x}_i, \lambda)} - \mu_i^2 \quad (5)$$

Chapitre 02 : le modèle de mélange gaussien

Exemple :

Si nous avons un ensemble de données composé de $N = 1000$ points tridimensionnels ($D = 3$), alors $\mathbf{x}$ sera une matrice 1000×3 . μ sera un vecteur 1×3 et Σ sera une matrice 3×3 . Pour des raisons ultérieures, nous trouverons également utile de prendre le logarithme de cette équation, qui est donné par :

$$\ln \mathcal{N}(\mathbf{x}|\mu, \Sigma) = -\frac{D}{2} \ln 2\pi - \frac{1}{2} \ln \Sigma - \frac{1}{2} (\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu) \quad (6)$$

2.3. Formules du modèle de mélange gaussien :

Pour déterminer quelle est la probabilité qu'un point de données $\mathbf{x}_n$ provienne d'un k gaussien. Nous pouvons exprimer cela ainsi :

$$p(z_{nk} = 1 | \mathbf{x}_n) \quad (7)$$

z est une variable latente qui ne prend que deux valeurs possibles. C'est un lorsque $\mathbf{x}$ vient de la gaussienne k , et zéro sinon. En fait, nous ne voyons pas cette variable z dans la réalité, mais connaître sa probabilité d'apparition nous sera utile pour aider à déterminer les paramètres du mélange gaussien.

$$\pi_k = p(z_k = 1) \quad (8)$$

Ce qui signifie que la probabilité globale d'observer un point issu de la gaussienne k est en réalité équivalente au coefficient de mélange de cette gaussienne. Cela est logique, car plus le gaussien est grand, plus cette probabilité est élevée. z l'ensemble de toutes les variables latentes possibles z , donc :

$$\mathbf{z} = \{z_1, \dots, z_K\} \quad (10)$$

Chapitre 02 : le modèle de mélange gaussien

Chaque z apparaît indépendamment des autres et qu'ils ne peuvent prendre la valeur un que lorsque k est égal au cluster d'où provient le point. Donc :

$$p(\mathbf{z}) = p(z_1 = 1)^{z_1} p(z_2 = 1)^{z_2} \dots p(z_K = 1)^{z_K} = \prod_{k=1}^K \pi_k^{z_k} \quad (11)$$

Il s'avère qu'il s'agit en fait de la fonction gaussienne elle-même ! En suivant la même logique que celle utilisée pour définir $p(\mathbf{z})$:

$$p(\mathbf{x}_n | \mathbf{z}) = \prod_{k=1}^K \mathcal{N}(\mathbf{x}_n | \mu_k, \Sigma_k)^{z_k} \quad (12)$$

L'objectif initial était de déterminer la probabilité de $\mathbf{z}$ compte tenu d'observation $\mathbf{x}$. Il s'avère que les équations que venir de dériver, ainsi que la règle de Bayes, aider à déterminer cette probabilité. D'après la règle des probabilités du produit :

$$p(\mathbf{x}_n, \mathbf{z}) = p(\mathbf{x}_n | \mathbf{z}) p(\mathbf{z}) \quad (13)$$

$$p(\mathbf{x}_n) = \sum_{k=1}^K p(\mathbf{x}_n | \mathbf{z}) p(\mathbf{z}) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \mu_k, \Sigma_k) \quad (14)$$

C'est l'équation qui définit le mélange gaussien, et vous voyez qu'elle dépend de tous les paramètres mentionnés.

2.4. La méthode d'expectation maximisation (EM) du modèle de mélange gaussien :

L'algorithme EM est un algorithme itératif très utilisé pour la recherche des paramètres au sens du maximum de vraisemblance sur des données incomplètes. L'astuce de l'EM est de ne pas maximiser la fonction de vraisemblance intraitable mais une fonction plus simple dénie par la densité des données complètes : $P_Z[\Phi_Y(\mathbf{z} | \Phi_Y)]$, avec $Z = (X, Y)$ (Y est la variable cachée). Chaque itération de l'EM est composée de deux étapes, la première est l'étape de calcul d'espérance et la deuxième est l'étape de maximisation des données estimées [22].

Chapitre 02 : le modèle de mélange gaussien

L'algorithme d'attente-maximisation (EM). Il est largement utilisé pour les problèmes d'optimisation où la fonction objectif présente des complexités telles que celle que nous venons de rencontrer pour le cas GMM.

Soit les paramètres de ce modèle :

$$\theta = \{\pi, \mu, \Sigma\} \quad (15)$$

Les étapes de l'algorithme EM. [9]

- **Étape 1**

Initialisez θ en conséquence.

- **Étape 2 : Étape des attentes (expectation) [9]**

$$Q(\theta^*, \theta) = \mathbb{E}[\ln p(\mathbf{X}, \mathbf{Z}|\theta^*)] = \sum_{\mathbf{Z}} p(\mathbf{Z}|\mathbf{X}, \theta) \ln p(\mathbf{X}, \mathbf{Z}|\theta^*) \quad (16)$$

$$p(z_k = 1|\mathbf{x}_n) = \frac{\pi_k \mathcal{N}(\mathbf{x}_n|\mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(\mathbf{x}_n|\mu_j, \Sigma_j)} = \gamma(z_{nk}) \quad (17)$$

Avec compensation :

$$Q(\theta^*, \theta) = \sum_{\mathbf{Z}} \gamma(z_{nk}) \ln p(\mathbf{X}, \mathbf{Z}|\theta^*) \quad (18)$$

pour trouver $p(\mathbf{X}, \mathbf{Z}|\theta^*)$ en utilisant l'expression suivante :

$$p(\mathbf{X}, \mathbf{Z}|\theta^*) = \prod_{n=1}^N \prod_{k=1}^K \pi^{z_{nk}} \mathcal{N}(\mathbf{x}_n|\mu_k, \Sigma_k)^{z_{nk}} \quad (19)$$

Qui est le résultat du calcul de la probabilité conjointe de toutes les observations et variables latentes et est une extension de dérivations initiales pour $p(\mathbf{x})$. Le log de

Chapitre 02 : le modèle de mélange gaussien

cette expression est donné par :

$$\ln p(\mathbf{X}, \mathbf{Z}|\theta^*) = \sum_{n=1}^N \sum_{k=1}^K z_{nk} [\ln \pi_k + \ln \mathcal{N}(\mathbf{x}_n|\mu_k, \Sigma_k)] \quad (20)$$

L'équation (20) dans (18) pour obtenir :

$$\mathcal{Q}(\theta^*, \theta) = \sum_{n=1}^N \sum_{k=1}^K \gamma(z_{nk}) [\ln \pi_k + \ln \mathcal{N}(\mathbf{x}_n|\mu_k, \Sigma_k)] \quad (21)$$

• Étape 3 : Étape de maximisation

Trouvez les paramètres révisés θ^* en utilisant :[9]

$$\theta^* = \arg \max_{\theta} \mathcal{Q}(\theta^*, \theta) \quad (22)$$

Où :

Dans l'équation (21) :

Q doit également prendre en compte la restriction selon laquelle toutes les valeurs de π doivent totaliser un. Pour ce faire, on doit ajouter un multiplicateur de Lagrange adapté. Par conséquent, on doit réécrire l'équation (10) de cette manière :

$$\mathcal{Q}(\theta^*, \theta) = \sum_{n=1}^N \sum_{k=1}^K \gamma(z_{nk}) [\ln \pi_k + \ln \mathcal{N}(\mathbf{x}_n|\mu_k, \Sigma_k)] - \lambda \left(\sum_{k=1}^K \pi_k - 1 \right) \quad (23)$$

Maintenant, on peut facilement déterminer les paramètres en utilisant le maximum de vraisemblance. Prend maintenant la dérivée de Q par rapport à π et fixons-la

égale à zéro :

$$\frac{\partial \mathcal{Q}(\theta^*, \theta)}{\partial \pi_k} = \sum_{n=1}^N \frac{\gamma(z_{nk})}{\pi_k} - \lambda = 0 \quad (24)$$

Ensuite, en réorganisant les termes et en appliquant une sommation sur k aux deux côtés de l'équation, on obtient :

$$\sum_{n=1}^N \gamma(z_{nk}) = \pi_k \lambda \implies \sum_{k=1}^K \sum_{n=1}^N \gamma(z_{nk}) = \sum_{k=1}^K \pi_k \lambda \quad (25)$$

Chapitre 02 : le modèle de mélange gaussien

D'après l'équation : (1)

La somme des probabilités γ sur k nous donnera également 1. Nous obtenons ainsi $\lambda = N$. En utilisant ce résultat, on peut résoudre pour π :

$$\pi_k = \frac{\sum_{n=1}^N \gamma(z_{nk})}{N} \quad (26)$$

On utilise ces valeurs révisées pour déterminer γ lors de la prochaine itération EM et ainsi de suite jusqu'à ce qu'on voie une certaine convergence dans la valeur de vraisemblance.

2.5. Algorithme de la méthode GMM :

Initialisation :

Choisir le nombre de composantes gaussiennes, K .

Initialiser les paramètres du modèle :

Poids des composantes, π_k pour $k=1, \dots, K$.

Moyenne des composantes, μ_k pour $k=1, \dots, K$.

Matrices des covariances des composantes, Σ_k pour $k=1, \dots, K$.

Expectation :

Pour chaque point de donnée x_i et chaque composante k , calculer la responsabilité γ_{ik} :

$$p(z_k = 1 | \mathbf{x}_n) = \frac{\pi_k \mathcal{N}(\mathbf{x}_n | \mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(\mathbf{x}_n | \mu_j, \Sigma_j)} = \gamma(z_{nk}) \quad (17)$$

où $(x_i | \mu_k, \Sigma_k)$ est la densité de probabilité de la distribution normale multi variée avec les paramètres μ_k et Σ_k .

Chapitre 02 : le modèle de mélange gaussien

Maximisation :

Mettre à jour les poids des composantes π_k , Moyenne μ_k et covariances Σ_k .

Vérifie la convergence.

Si a converge donc arrêter, sinon retourner à l'étape expectation.

Les paramètres π_k , μ_k , et Σ_k sont les estimations finales des paramètres du modèle.

2.6. Quelques méthodes sur la méthode GMM :

Ces méthodes fournissent des données précieuses sur l'impact de GMM, ce qui soutient l'hypothèse de notre recherche sur les bénéfices et les défis de modèle de mélange gaussien.

Modèle de mélange gaussien avec cohérence locale Consistency [28]:

Dans l'article [28], ils proposent un nouvel algorithme basé sur un modèle pour le regroupement de données, appelé modèle de mélange gaussien localement cohérent (LCGMM), qui considère explicitement la structure multiple. Suivant l'intuition selon laquelle les données naturelles peuvent résider sur ou à proximité d'une sous-variété du espace ambiant, ils incorporent un régulariser dans la fonction objectif du modèle de mélange gaussien après avoir construit un graphique du voisin le plus proche et en adoptant la divergence de Kullback-Leibler comme mesure de « distance ». Il est important de noter que les travaux présentés ici sont fondamentalement basés sur ses travaux précédents LapGMM (He et al. 2010). Le principal La différence est que LapGMM construit le régulariseur en utilisant distance euclidienne et utilise l'EM généralisée pour estimer les paramètres. ils utilisent la KL-Divergence pour mesurer la « distance » de deux distributions de probabilité qui est beaucoup plus naturel. De plus, en utilisant KL-Divergence, le Une nouvelle fonction objectif peut être résolue plus efficacement par un algorithme EM ordinaire.

Le modèle LCGMM offre une méthode avancée pour le regroupement de données, en tenant compte de la structure locale des données via un graphique des k-plus proches voisins et en utilisant la KL-Divergence comme mesure de distance. Cela permet une régularisation plus naturelle et une optimisation plus efficace par rapport aux modèles précédents comme LapGMM.

Chapitre 02 : le modèle de mélange gaussien

En suivant leur méthodologie, on peut appliquer le LCGMM pour effectuer un regroupement de données plus cohérent et précis, en particulier pour des données qui résident sur ou à proximité de sous-variétés de l'espace ambiant.

Ils ont utilisé 8 bases de données et ont observé que GMM fonctionnait très mal sur deux d'entre eux, tandis que LCGMM fonctionnait raisonnablement bien sur ces deux ensembles de données. Notre raison est que le GMM traditionnel ne prend pas en compte la structure géométrique locale des données. En incorporant un régulariser localement cohérent, LCGMM évite cette limitation.

Algorithme de détection d'objet image basé sur un modèle de mélange gaussien amélioré [29] :

La faible adaptabilité à la variation d'éclairage et un taux d'apprentissage unique dans le modèle de mélange gaussien traditionnel, un algorithme amélioré de détection d'objets en mouvement basé sur un modèle de mélange gaussien adaptatif est proposé dans cet article, de manière à atteindre l'objectif d'un modèle de mise à jour d'arrière-plan auto-adaptatif.

Dans l'article [29], ils ont proposé un algorithme complet de détection et de segmentation des bâtiments dans les RSI haute résolution. Cet algorithme contient principalement trois étapes : 1) détection des ombres, 2) détection des bâtiments et segmentation approximative, 3) segmentation précise basée sur un ensemble de niveaux.

Dans un premier temps, ils combinent quelques algorithmes pour détecter les zones d'ombre ; dans la deuxième étape, un algorithme de croissance régionale contrainte est présenté pour trouver approximativement les emplacements et les zones des bâtiments ; enfin, la segmentation précise des bâtiments est réalisée sur la base d'un modèle d'ensemble de niveaux.

Les résultats de l'expérience montrent que la nouvelle méthode peut adapter efficacement la scène et présente plus d'évolutivité, de robustesse et de stabilité que le modèle de mélange gaussien traditionnel. Il est efficace, puissant et précis par rapport à certains modèles concurrents.

2.7. Conclusion :

Dans ce chapitre, nous avons essayé de parler du modèle de mélange gaussien et de l'algorithme de maximisation des attentes (EM) et de ses étapes, GMM est un outil très puissant et largement utilisé dans diverses tâches de regroupement de données. On peut utiliser dans la segmentation d'images, reconnaissance des formes, analyse de données et clustering...ext.

Dans le chapitre suivant, on présentera comment segmenter une image 2D à l'aide d'un modèle de mélange gaussien (GMM).

Chapitre 03 :
Implémentation et résultats

3.1. Introduction

Dans ce travail, je m'intéresse au développement d'un algorithme de modèle de mélange gaussien (GMM) pour la segmentation d'images. Pour cette raison, j'ai implémenté deux schémas de segmentation : la segmentation basée sur un modèle de mélange gaussien et la segmentation d'images basée sur un modèle de mélange gaussien avec résolution. L'objectif de cette partie est de comparer ces méthodes de segmentation.

3.2. Matériel Utilisé :

Un micro-ordinateur « Asus » avec les caractéristiques suivantes :

Processeur Intel(R) Core(TM) i3 6006U CPU @ 2.00 GHz 1.99 GHz

RAM 4.00 GB

Disque Dur 500 GB HDD

On a utilisé le langage python dans Jupiter notebook.

3.3. Description des données

Les données utilisées dans cette étude comprennent des images médicales et des images générales. Les images médicales sont particulièrement intéressantes car elles contiennent souvent des structures complexes et de grandes différences de contraste. Les photographies peuvent concerner des paysages urbains, naturels ou autres, et offrir une large gamme de couleurs et de textures. Les images utilisées sont les suivantes :




Figure04 : brain_b




Figure05 : brain_2



Figure06 : knee




Figure07 : Meningioma

3.4. Implémentation du Modèle de Mélange Gaussien

- **Importer les bibliothèques nécessaires :**

On a travaillé dans trois bibliothèques :

cv2, numpy , GaussianMixture.

- **Charger les données(les images) :**

Chargement de l'image depuis le chemin spécifié.

Conversion de l'espace de couleur de BGR (par défaut dans OpenCV) à RGB.

- **Restructurer de l'image en une matrice de pixels :**

on transforme l'image en une matrice 2D où chaque ligne représente un pixel avec ses valeurs de couleur RGB.

- **Définir le nombre de clusters (k) et appliquer le modèle GMM :**

On Initialise du modèle GMM avec le nombre de clusters souhaité.

- **Prédiction des labels des pixels et obtention des centres des clusters.**

- **Conversion des centres des clusters en type uint8 :**

Conversion des centres des clusters en valeurs de couleur 8 bits (0-255).

- **Mapper les labels des pixels aux centres des clusters :**

Attribution des valeurs des centres des clusters aux pixels en fonction des labels.

- **Restructurer de l'image segmentée et affichage :**

On Restructure de l'image segmentée pour retrouver les dimensions originales de l'image et j'affiche l'image segmentée.

L'organigramme :




Figure08 : organigramme de l'implémentation du modèle GMM.

3.5. Validation et Évaluation

L'évaluation visuelle d'images segmentées est réalisée par un expert humain, qui compare visuellement l'image initiale à l'image segmentée. Cette méthode est subjective car elle dépend des critères spécifiques de l'expert, liés à son domaine d'intérêt et à ses objectifs. Ces critères peuvent inclure des aspects tels que les objets, les zones homogènes ou texturées, et les discontinuités. Bien que qualitative, cette évaluation peut indiquer si un algorithme fonctionne, mais elle ne permet pas de comparer plusieurs algorithmes entre eux. Pour améliorer cette évaluation, on peut consulter plusieurs experts et ne retenir que les résultats cohérents. Pour une évaluation quantitative de la segmentation, diverses métriques comme la précision sont utilisées, permettant de mesurer la qualité de la segmentation par rapport à des données de référence ou des vérités terrain. La validation s'est faite à l'aide de données étiquetées manuellement et en comparant les résultats aux attentes.

3.6. Résultats de la segmentation

Les résultats de la segmentation montrent des exemples de segmentation réussie. Les images avant et après segmentation révèlent des différences nettes, avec des segments distincts et des contours clairement définis. Les segments correspondant à différentes régions d'intérêt sont bien identifiés, que ce soit pour des images médicales ou des photographies.

3.7. Analyse des résultats

Je vais commencer par donner les résultats obtenus par la segmentation basée sur mélange gaussien.

Pour la première image meningioma pour $k=2$, 3 et 4 :




Figure09 : l'image meningioma segmentée par GMM.

Chapitre 03 : Implémentation et résultats

Pour la deuxième image *brain_2* pour $k=2$, 3 et 4 :




Figure10 : l'image *brain_2* segmentée par GMM.

Pour la troisième image *brain_b* pour $k=2$, 3 et 4:




Figure11 : l'image *brain_b* segmentée par GMM.

Pour la quatrième image *knee* pour $k=2$, 3 et 4 :




Figure12 : l'image *knee* segmentée par GMM.

Chapitre 03 : Implémentation et résultats

L'analyse des résultats de segmentation d'images basée sur le modèle de mélange gaussien (GMM) révèle plusieurs points importants concernant l'efficacité et les limites de cette méthode. Elle est capable de produire des segments cohérents et bien définis dans des images complexes. Chaque segment correspond généralement à une région homogène en termes d'intensité de pixel et robuste face aux variations d'intensité au sein des segments. Il peut efficacement distinguer des zones de densité similaire, même en présence de gradations ou de différences d'éclairage.

Quant aux limitations observées, elles incluent : Premièrement, la qualité des coupes obtenues par GMM dépend fortement de la configuration des paramètres. Si les centres de cluster sont mal configurés, cela peut conduire à des résultats sous-optimaux. Deuxièmement, il est nécessaire de choisir un nombre approprié de composantes gaussiennes pour le GMM. Un nombre trop élevé ou trop faible peut entraîner respectivement un sous-partitionnement ou un surpartitionnement. Ce paramètre nécessite souvent des essais et des erreurs ou des méthodes heuristiques pour être déterminé correctement. Troisièmement, l'algorithme EM (Expectation Maximisation) utilisé pour régler les paramètres GMM peut nécessiter beaucoup de calculs, en particulier pour les grandes images ou les modèles comportant de nombreuses composantes gaussiennes.

3.8. Comparaisons avec d'autres méthodes

3.8.1. Segmentation d'image basée sur mélange gaussien avec résolution :

La résolution :

Pour la première image :



Figure13 : image meningioma avec la résolution 1/2, 1/3 et 1/4.

Pour la deuxième image :



Figure14 : image brain_2 avec la résolution 1/2, 1/3 et 1/4.

Chapitre 03 : Implémentation et résultats

Pour la troisième image :




Figure15 : image brain_b avec la résolution 1/2, 1/3 et 1/4.

Pour la quatrième image :



Figure16 : image knee avec la résolution 1/2, 1/3 et 1/4.

Chapitre 03 : Implémentation et résultats

Pour une segmentation d'image basée sur un mélange gaussien précis, nous avons divisé les dimensions de l'image par n , puis segmenté l'image résultante par GMM, puis multiplié les dimensions de l'image par le même nombre n pour obtenir une image de même taille que l'image initiale.

Pour la première image pour $k=3$ et $n=2$:




Figure17 : image meningioma segmentée GMM et GMM avec résolution.




Figure18 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image meningioma.

Chapitre 03 : Implémentation et résultats

Pour la deuxième image pour $k=3$ et $n=2$:




Figure19 : image brain_2 segmentée GMM et GMM avec résolution.




Figure20 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image brain_2.

Chapitre 03 : Implémentation et résultats

Pour la troisième image pour $k=3$ et $n=2$:




Figure21 : image brain_b segmentée avec GMM et GMM avec résolution.




Figure22 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image brain_b.

Chapitre 03 : Implémentation et résultats

Pour la quatrième image pour $k=3$ et $n=2$:




Figure23 : image knee segmentée GMM et GMM avec résolution.




Figure24 : La différence de pourcentage de poids de chacun classe de l'image entre la segmentation par GMM et la segmentation par GMM avec résolution, pour l'image knee.

Chapitre 03 : Implémentation et résultats

3.8.2. Manuelle :

La segmentation manuelle présente plusieurs difficultés, notamment en matière de coût, de temps et d'uniformité. Premièrement, dans de nombreuses applications, la personne qui annote les images doit être spécialiste du domaine, ce qui rend la segmentation manuelle difficile et coûteuse sur le plan opérationnel.

3.8.3. Comparaison :

	GMM	GMM Avec résolution	manuelle
<i>Simplicité</i>	<i>Plus simple à implémenter.</i>	<i>Plus complexe à implémenter.</i>	<i>Plus complexe à faire</i>
<i>Détails et structure</i>	<i>manquer de détails fins</i>	<i>Capture les détails fins et les structures globales</i>	<i>Difficulté avec les frontières floues et les détails fins.</i>
<i>Robustesse au bruit</i>	<i>Moins robuste.</i>	<i>Plus robuste.</i>	<i>Plus robuste pour les gens qui ont l'expérience</i>

Figure 25 : tableau montre la différence entre GMM et GMM avec résolution.

La segmentation d'images basée sur GMM est plus simple et plus rapide, mais peut-être moins précise et robuste, en particulier sur les images complexes. En revanche, l'approche de résolution, bien que plus complexe et peut-être plus lente, offre une meilleure qualité de segmentation en capturant des informations à différents niveaux et est plus robuste face aux variations d'image. Quant à la segmentation manuelle, elle est longue et nécessite une expérience particulière en images médicales ou dans tout autre domaine.

3.9. Conclusion

Le modèle de mélange gaussien est un puissant outil de segmentation d'images, capable de gérer des images complexes et de produire des segments cohérents. Cependant, son efficacité est limitée par la sensibilité à l'initialisation des paramètres et par la nécessité d'un ajustement approprié du nombre de composants. Une bonne initialisation et une sélection appropriée de paramètres sont essentielles pour obtenir des résultats optimaux.

Conclusion générale

Conclusion générale

Dans cette mémoire, on a exploré l'utilisation du modèle de mélange gaussien (GMM) pour la segmentation d'images. Nous avons comparé deux méthodes distinctes : la première est Segmentation basée sur GMM, la deuxième est Segmentation basée sur GMM avec une résolution.

Les principaux points de notre investigation et les découvertes majeures sont les suivants : la méthode GMM repose uniquement sur les caractéristiques d'intensité des pixels pour segmenter l'image. Bien que cette approche soit simple et directe, elle tend à produire des segments discontinus et moins cohérents spatialement, car elle ignore les informations de voisinage. GMM avec résolution spatiale : En intégrant une composante spatiale, cette méthode améliore la cohérence des segments en tenant compte des relations spatiales entre les pixels. Ceci se traduit par des segments plus homogènes et mieux définis.

Les résultats montrent que l'intégration de la résolution spatiale dans le GMM permet d'obtenir des segments plus précis et visuellement cohérents, améliorant ainsi la qualité globale de la segmentation.

Il y a aussi de nombreuses limites à mentionner par exemple : L'intégration de la composante spatiale augmente la complexité informatique du modèle, ce qui peut rendre l'algorithme plus lent et gourmand en ressources, en particulier pour les grandes images. Les performances du GMM avec la résolution spatiale dépendent fortement du choix des paramètres, tels que le nombre de composantes gaussiennes et le poids accordé à la composante spatiale. Une mauvaise sélection de ces paramètres peut détériorer la qualité de la segmentation. GMM repose sur l'hypothèse que les données suivent une distribution gaussienne, ce qui n'est pas toujours le cas pour toutes les caractéristiques de l'image, ce qui limite sa flexibilité.

À l'avenir, nous pourrions optimiser les paramètres et développer des moyens d'automatiser la sélection des paramètres GMM, peut-être via des techniques d'apprentissage automatique, afin d'améliorer la robustesse et la convivialité de l'approche.

Conclusion générale

En conclusion, bien que l'intégration de la résolution spatiale dans GMM améliore considérablement la qualité de la segmentation, des défis demeurent en termes de complexité et de paramétrage. Les travaux futurs devraient se concentrer sur l'amélioration de l'efficacité et de la flexibilité du modèle pour une application plus large et plus efficace.

Bibliographie

- [1] M .T.Chikh , amélioration des images par un modèle de réseau de neurones (comparaison avec les filtres de base), université abou-bakr belkaid tlemcen.2011
- [2] C.Houassine, segmentation d'images par une approche biomimétique hybride.université mohamed bougara- boumerdes. 2012.
- [3] A.Medjaoui , f.fares , segmentation des images par contours actifs : application sur les Images Satellitaires à Haute Résolutions, Université Abou Bakr Belkaid tlemcen.2012.
- [4] T.Mohamed ,D.Djafar, la découverte des concepts sémantiques cachés avec plusieurs c niveaux d'abstraction pour la recherche d'images,université kasdi merbah ouargla.2013
- [5] M Sandeli, traitement d'images par des approches bio-inspirées application à la segmentation d'images, université constantine 2. 2014.
- [6] N MERABET,M MAHLIA, recherche d'images par le contenu, université abou bakrbelkaid– tlemcen.2011.
- [7] Mohamed SANDELI, Traitement d'images par des approches bio-inspirées Application à la segmentation d'images, Université Constantine 2,2014
- [8] M. Melliani, segmentation d'image par cooperation regions-contours, magistère en informatique, ecole national supérieur d'informatique, 2012.
- [9] Xu, L., Jordan, M.I., "On Convergence Properties of the EM Algorithm for Gaussian Mixture", Neural Computation, 8, 1996, PP. 129-151.
- [11] M. Fontaine 2001 : "segmentation non supervisée d'images couleur par analyse de la connexité des pixels", thèse de doctorat, université de Lille 1, France.
- [12] Mr. RABIA NacimRevue des méthodes de segmentation d'images texturées : cas des images couleur, UNIVERSITE MOULOUD MAMMERI DE TIZI OUZOU.2011

Bibliographie

- [13]** LOUDNI MAHMOUD, *segmentation d'image par les méthodes de contours actifs*, université SAAD DAHLAB de BLIDA, 2019
- [14]** Marechal Menrt. *Phoenix Publication un sujet qui Mérite Débat la ville Americaine*, 2002
- [15]** Reynolds, D.A.: *A Gaussian Mixture Modeling Approach to Text-Independent Speaker Identification*. PhD thesis, Georgia Institute of Technology (1992)
- [16]** BELHAMRA Hadjira, MELZI Soumia. *La segmentation d'image par Croissance de régions*. E.S.I. ALGERIE. 2009 / 2010.
- [17]** Mr HOUASSINE Charif, *Segmentation d'images par une approche biomimétique hybride*. UNIVERSITE M'HAMED BOUGARA-BOUMERDES, 2012
- [18]** Laurienne, S., "Fusion d'approches non-supervisées et génériques pour la segmentation thématique", Université d'Avignon, (2000).
- [19]** Deriche, R., "Using Canny's criteria to derive a recursively implemented optimal edge detector", *Int. Journal of Computer Vision*, vol.1, n°2, (1987) , 167-187.
- [20]** Busin, L. Vandenbroucke, N., Macaire, L. et Postaire, J.G., "Color space selection for unsupervised color image segmentation by histogram multithresholding", *Proceedings of the IEEE International Conference on Image Processing ICIP*, (2004).
- [21]** S. Van Dongen. *Graph clustering by ow simulation*. Thèse doctorat, Université d'Utrecht, Netherlands, Mai 2000.
- [22]** Rachid Hedjam, *Segmentation non-supervisée d'images couleur par sur-segmentation Markovienne en régions et procédure de regroupement de régions par graphes pondérés*, Université de Montréal, 2008
- [23]** Alain Boucher, *traitement d'images et vision par ordinateur IFI*, 2009
- [24]** H. Kagawa, M. Kinouchi et al "Image Segmentation by Artificial Life Approach using Autonomous Agents", *International Joint Conference on Neural Networks*, 1999

Bibliographie

[25] J-P.Cocquerez, S.Philipp, "Analyse d'images : filtrage et Segmentation", Masson, Paris, 1995.

[26] charchar ziyad, meddahi amina, segmentation et détection de contours des images , universite hassiba benbouali chlef, 2023

[27] Reynolds, D. A. (1995). Speaker identification and verification using Gaussian mixture speaker models. *Speech communication*, 17(1), 91-108.

[28] Jialu Liu, Deng Cai , Xiaofei He, Gaussian Mixture Model with Local Consistency, State Key Lab of CAD&CG, College of Computer Science, Zhejiang University, China

[29] LI Xing-liang , WU Yu-bao ,Image Object Detection Algorithm Based on Improved Gaussian Mixture Model , Nanjing Forest police College, Nanjing Jiangsu, 210023, China

[30] Hacène BELKACEMI, Extraction automatique de métadonnées à partir d'images de manuscrits anciens numérisés, UNIVERSITE MOULOUD MAMMERI DE TIZI-OUZOU, 2016

[31] MaitineBergounioux, « Quelques méthodes de filtrage en Traitement d'Image. Cours donnée dans le cadre d'une école CIMPA - en attente de publication dans les actes. 2010.