

7

Segmentation d'image

7.1 Introduction

La segmentation d'image consiste à partitionner une image en ses régions et objets constitutifs. Le niveau de détail pour lequel le partitionnement est effectué dépend du problème à traiter. Autrement dit, la segmentation devrait s'arrêter lorsque les objets ou régions d'intérêt dans une application ont été détectés. Par exemple, dans une application telle que l'assemblage des composants électronique, l'objectif consiste à déterminer la présence ou l'absence d'anomalies spécifiques, telle que la présence des défauts de fabrication. Les algorithmes de segmentation dans ce chapitre sont basés sur l'une des deux propriétés de base des valeurs d'intensité : *la discontinuité* et *la similitude*. Dans ce chapitre, nous discutons et illustrons les approches de base pour la segmentation d'image.

7.2 Définition

La segmentation d'image est la division de l'image en plusieurs régions homogènes (segmentation partielle), ou bien en objets ayant un sens sémantique (segmentation complète). Dans ce chapitre, nous étudierons quelques algorithmes célèbres qui font la segmentation partielle. De manière formelle:

Le problème revient à construire une partition $\{R_1, \dots, R_K\}$ de l'image I , qui respecte les conditions suivantes:

- R_i connexe et homogène.
- $R_i \cap R_j = \emptyset, \forall i \neq j$
- $\bigcup_{i=1}^K R_i = I$

7.3 Un algorithme global de base pour le seuillage

Il est possible d'utiliser un seuil *global* appliqué sur toute l'image lorsque les distributions des valeurs des pixels des objets et d'arrière-plan sont suffisamment distinctes. Un algorithme pour l'estimation automatique du seuil pour chaque image est nécessaire. L'algorithme itératif suivant peut être utilisé pour cet objectif :

- 1) Choisir une estimation initiale pour le seuil global, T .
- 2) Segmenter l'image à l'aide de la valeur actuelle de T . Cela va produire deux groupes de pixels: \mathbf{G}_1 constitué de tous les pixels ayant une intensité $> T$ et \mathbf{G}_2 constitué des pixels avec des intensités $\leq T$.
- 3) Calculer les valeurs moyennes d'intensité m_1 et m_2 pour les pixels en \mathbf{G}_1 et \mathbf{G}_2 , respectivement.
- 4) Calculer la nouvelle valeur de seuil par la formule:

$$T = \frac{1}{2}(m_1 + m_2) \quad (7.1)$$

- 5) Répétez les étapes 2 à 4 jusqu'à ce que la différence entre les valeurs de T en deux itérations successives soit inférieure à un paramètre prédéfini ΔT .

Cet algorithme simple est efficace dans les situations où il existe une vallée suffisamment grande entre les modes objets et arrière-plan de l'histogramme. Le paramètre ΔT permet de contrôler le nombre d'itérations pour les différentes applications. En général, plus ΔT est grand, moins le nombre d'itérations effectué par l'algorithme. Le seuil initial doit être compris entre le minimum et le maximum des niveaux de gris de l'image. La moyenne de l'image est un bon choix pour initialiser T .

La Fig. 7.1 montre un exemple de segmentation basé sur un seuil qui a été estimé en utilisant l'algorithme précédent. Les Fig. 7.1(a) et 7.1(b) représentent, respectivement, l'image originale et l'histogramme de l'image, ce dernier montre une vallée distinctive. L'application de l'algorithme itératif précédent a abouti à un seuil $T = 125.4$ après trois itérations, en commençant par $T = m$ (l'intensité moyenne de l'image) et en utilisant $\Delta T = 0$. La Fig. 7.1(c) montre le résultat obtenu en utilisant $T = 125$ pour segmenter l'image originale.

7.4 Seuillage global et optimal par la méthode d'Otsu

7.4.1 Algorithme d'Otsu

La méthode d'Otsu (1979) est une alternative très intéressante. Cette méthode est optimale dans le sens où elle maximise la *variance inter-classe*. L'idée de base est que les classes doivent être distinctes par rapport aux valeurs d'intensité de leurs pixels et, inversement, le seuil optimal est celui qui donne la meilleure séparation entre les classes en termes d'intensité. En plus de son optimalité, l'algorithme d'Otsu repose entièrement sur des calculs réalisés sur l'histogramme de l'image qui est un tableau 1-D facile à obtenir.

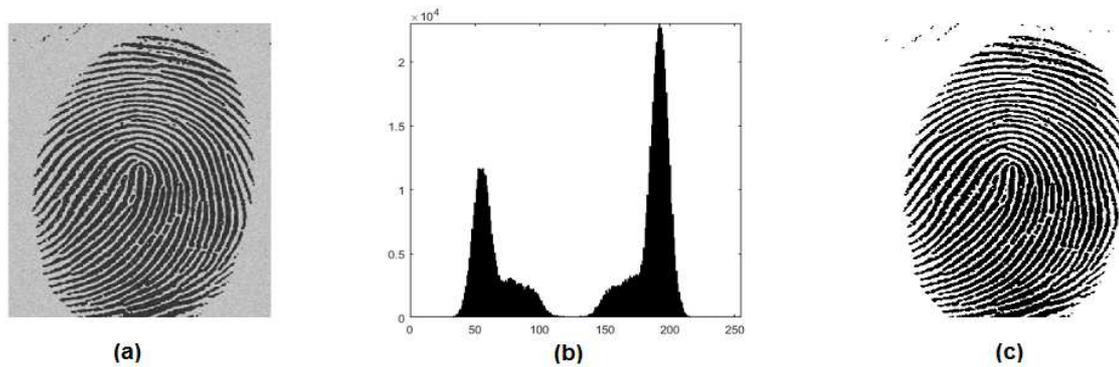


FIG. 7.1: (a) Image d'empreinte bruitée. (b) Histogramme. (c) Résultat de segmentation en utilisant la méthode de seuillage global ($T = 125$).

Soient $\{0, 1, 2, \dots, L - 1\}$ les L niveaux d'intensité distincts dans une image numérique de taille $M \times N$ pixels, et soit n_i le nombre d'occurrences des pixels ayant l'intensité i . Le nombre total des pixels dans l'image est $MN = n_0 + n_1 + n_2 + \dots + n_{L-1}$. L'histogramme normalisé aura les composantes $p_i = n_i/MN$, d'où on a:

$$\sum_{i=0}^{L-1} p_i = 1, \quad p_i \geq 0 \quad (7.2)$$

Maintenant, supposons que nous choisissons un seuil $T(k) = k$, $0 < k < L - 1$, pour diviser l'image d'entrée en deux classes, \mathbf{C}_1 et \mathbf{C}_2 , où \mathbf{C}_1 est constituée des pixels de l'image ayant les valeurs d'intensité dans l'intervalle $[0, k]$ et \mathbf{C}_2 formée des pixels ayant des valeurs dans l'intervalle $[k + 1, L - 1]$. En utilisant ce seuil, la probabilité, $P_1(k)$, qu'un pixel est affecté à la classe \mathbf{C}_1 est donnée par la somme cumulative

$$P_1(k) = \sum_{i=0}^k p_i \quad (7.3)$$

De même, la probabilité que la classe \mathbf{C}_2 se produise soit

$$P_2(k) = \sum_{i=k+1}^{L-1} p_i = 1 - P_1(k) \quad (7.4)$$

La valeur moyenne des intensités des pixels affectés à la classe \mathbf{C}_1 est

$$\begin{aligned} m_1(k) &= \sum_{i=0}^k iP(i|\mathbf{C}_1) \\ &= \sum_{i=0}^k i \frac{P(\mathbf{C}_1|i)P(i)}{P(\mathbf{C}_1)} \\ &= \frac{1}{P_1(k)} \sum_{i=0}^k ip_i \end{aligned} \quad (7.5)$$

où $P_1(k)$ est donné dans l'équation (7.3). Le terme $P(i|\mathbf{C}_1)$ dans la première ligne de l'équation (7.5) est la probabilité de la valeur i , sachant que i viens de la classe \mathbf{C}_1 . La deuxième ligne de l'équation découle de la formule de Bayes:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (7.6)$$

La troisième ligne découle du fait que $P(\mathbf{C}_1/i) = 1$ parce que nous traitons uniquement des valeurs i de la classe \mathbf{C}_1 . En plus, $P(i)$ est la probabilité de la i ème valeur, qui est simplement la i ème composante de l'histogramme, p_i . Enfin, $P(\mathbf{C}_1)$ est la probabilité de la classe \mathbf{C}_1 , qui est égal à $P_1(k)$, d'après l'Eq. (7.3).

De même, la valeur moyenne d'intensité des pixels affectés à la classe \mathbf{C}_2 est

$$m_2(k) = \sum_{i=k+1}^{L-1} iP(i|\mathbf{C}_2) = \frac{1}{P_2(k)} \sum_{i=k+1}^{L-1} ip_i \quad (7.7)$$

La moyenne cumulative (intensité moyenne) jusqu'à le niveau k est donnée par

$$m(k) = \sum_{i=0}^k ip_i \quad (7.8)$$

et la moyenne d'intensité de l'image entière (*i.e.* la moyenne *globale*) est donnée par

$$m_G = \sum_{i=0}^{L-1} ip_i \quad (7.9)$$

La validité des deux équations suivantes peut être vérifiée par substitution directe des résultats précédents:

$$P_1(k)m_1(k) + P_2(k)m_2(k) = m_G \quad (7.10)$$

et

$$P_1(k) + P_2(k) = 1 \quad (7.11)$$

Afin d'évaluer la qualité du seuil au niveau k , on utilise la métrique suivante

$$\eta(k) = \frac{\sigma_B^2(k)}{\sigma_G^2} \quad (7.12)$$

où σ_G^2 est la *variance globale*, c'est-à-dire la variance d'intensité de tous les pixels de l'image, donnée par l'équation,

$$\sigma_G^2 = \sum_{i=0}^{L-1} (i - m_G)^2 p_i \quad (7.13)$$

et σ_B^2 est la *variance intra-classes*, définie comme

$$\sigma_B^2(k) = P_1(k)(m_1(k) - m_G)^2 + P_2(k)(m_2(k) - m_G)^2 \quad (7.14)$$

Cette expression peut être aussi écrite comme

$$\begin{aligned} \sigma_B^2(k) &= P_1(k)P_2(k)(m_1(k) - m_2(k))^2 \\ &= \frac{(m_G P_1 - m(k))^2}{P_1(k)(1 - P_1(k))} \end{aligned} \quad (7.15)$$

où m_G et m sont déjà définis. La première ligne de cette équation découle des Eqs. (7.14), (7.10), et (7.11). La deuxième ligne découle des Eqs. (7.4) à (7.9). Cette forme est légèrement plus efficace en termes de temps calcul parce que le paramètre m_G n'est calculée qu'une seule fois, seulement $m(k)$ et $P_1(k)$ vont être calculés pour toutes les valeurs de k .

Notez que l'Eq. (7.12) suppose implicitement que $\sigma_G^2 > 0$. Cette variance peut être nulle uniquement lorsque tous les niveaux de gris de l'image sont identiques, ce qui implique l'existence d'une seule classe de pixels. Cela signifie, par contre, que $\eta = 0$ pour une image constante puisque la séparabilité d'une seule classe par rapport à elle-même est zéro.

Nous avons vu de la première ligne dans l'Eq. (7.15) que plus les deux moyennes m_1 et m_2 sont éloignés l'un de l'autre, plus la variance intra-classes σ_B^2 sera grande, cela indique que la variance intra-classes est une mesure de *séparabilité* entre les classes. Il s'ensuit que η est également une mesure de séparabilité, et minimiser cette métrique est équivalent à maximiser σ_B^2 . L'objectif donc est de déterminer la valeur de seuil k qui maximise la variance intra-classes, donc le seuil optimal est la valeur k^* qui maximise $\sigma_B^2(k)$:

$$k^* = \arg \max_k (\sigma_B^2(k)), \quad 0 \leq k \leq L - 1 \quad (7.16)$$

En d'autres termes, pour trouver k^* , nous évaluons simplement l'Eq. (7.16) pour toutes les valeurs entières de k (de telle sorte que la condition $0 < P_1(k) < 1$ soit vérifiée) et sélectionnez cette valeur de k qui a donné le maximum de $\sigma_B^2(k)$. Si le maximum existe pour plus d'une valeur de k , généralement, on prend la moyenne des différentes valeurs de k pour lesquelles $\sigma_B^2(k)$ est maximal. Il peut être montré qu'un maximum existe toujours, sous réserve que $0 < P_1(k) < 1$.

Une fois k^* obtenu, l'image d'entrée $f(x, y)$ est segmentée, pour $x = 0, 1, \dots, M - 1$ et $y = 0, 1, \dots, N - 1$:

$$g(x, y) = \begin{cases} 1 & \text{si } f(x, y) > k^* \\ 0 & \text{si } f(x, y) \leq k^* \end{cases} \quad (7.17)$$

La métrique normalisée η calculée au seuil optimale, $\eta(k^*)$, peut être utilisée pour obtenir une estimation quantitative de la séparabilité des classes, ce qui donne une idée de la facilité du seuillage d'une image donnée. Les valeurs possibles de $\eta(k^*)$ sont incluses dans l'intervalle

$$0 \leq \eta(k^*) \leq 1 \quad (7.18)$$

La limite inférieure "0" n'est atteinte que par des images ayant un seul niveau de gris constant, alors que la limite supérieure "1" n'est atteinte que par des images ayant deux valeurs d'intensité égales à 0 ou $L - 1$, respectivement.

L'algorithme d'Otsu peut être résumé en ce qui suit:

- 1) Calculer l'histogramme normalisé de l'image d'entrée (les composantes p_i).
- 2) Calculer les sommes cumulées, $P_1(k)$, pour $k = 0, 1, \dots, L - 1$, avec l'Eq. (7.3).
- 3) Calculer les moyennes cumulatives, $m(k)$, pour $k = 0, 1, \dots, L - 1$, avec l'Eq. (7.8).
- 4) Calculer la moyenne d'intensité globale, m_G , avec l'Eq. (7.9).
- 5) Calculer la variance intra-classes, $\sigma_B^2(k)$, pour $k = 0, 1, \dots, L - 1$ avec l'Eq. (7.15).
- 6) Trouver le seuil d'Otsu, k^* , la valeur de k pour laquelle $\sigma_B^2(k)$ est maximum. Si le maximum n'est pas unique, calculer k^* en faisant la moyenne des valeurs correspondantes aux différentes maxima détectées.
- 7) Trouver la mesure de séparabilité, η^* , en évaluant l'Eq. (7.12) pour $k = k^*$.

La Fig. 7.2(a) montre une image microscopique de cellules polymères, et la Fig. 7.2(b) montre son histogramme. L'objectif de cet exemple est de séparer les molécules de l'arrière-plan. La Fig. 7.2(c) montre le résultat de l'utilisation de l'algorithme de seuillage global de base de la Section 7.3. cet algorithme n'a pas réussi à atteindre la segmentation souhaitée parce que l'histogramme n'a pas de vallées distinctes et que la différence d'intensité entre le fond et les objets est très faible. La Fig. 7.2(d) montre le résultat obtenu en utilisant la méthode d'Otsu. Ce résultat est bien évidemment supérieur à celui de la Fig. 7.2(c). La valeur de seuil calculée par l'algorithme de base est de 169, alors que celui calculé par la méthode d'Otsu est de 181. La mesure de séparabilité η est de 0.467.

7.4.2 Remarques sur l'algorithme de seuillage

- Avantages:
 - 1) Simple et global.
 - 2) Très efficace pour les images à deux régions (objet sur un fond).
- Inconvénients:
 - 1) Difficile à étendre pour la couleur.
 - 2) Difficile à généraliser pour un nombre arbitraire de régions.
 - 3) Ne tient pas compte de l'information spatiale de l'image.

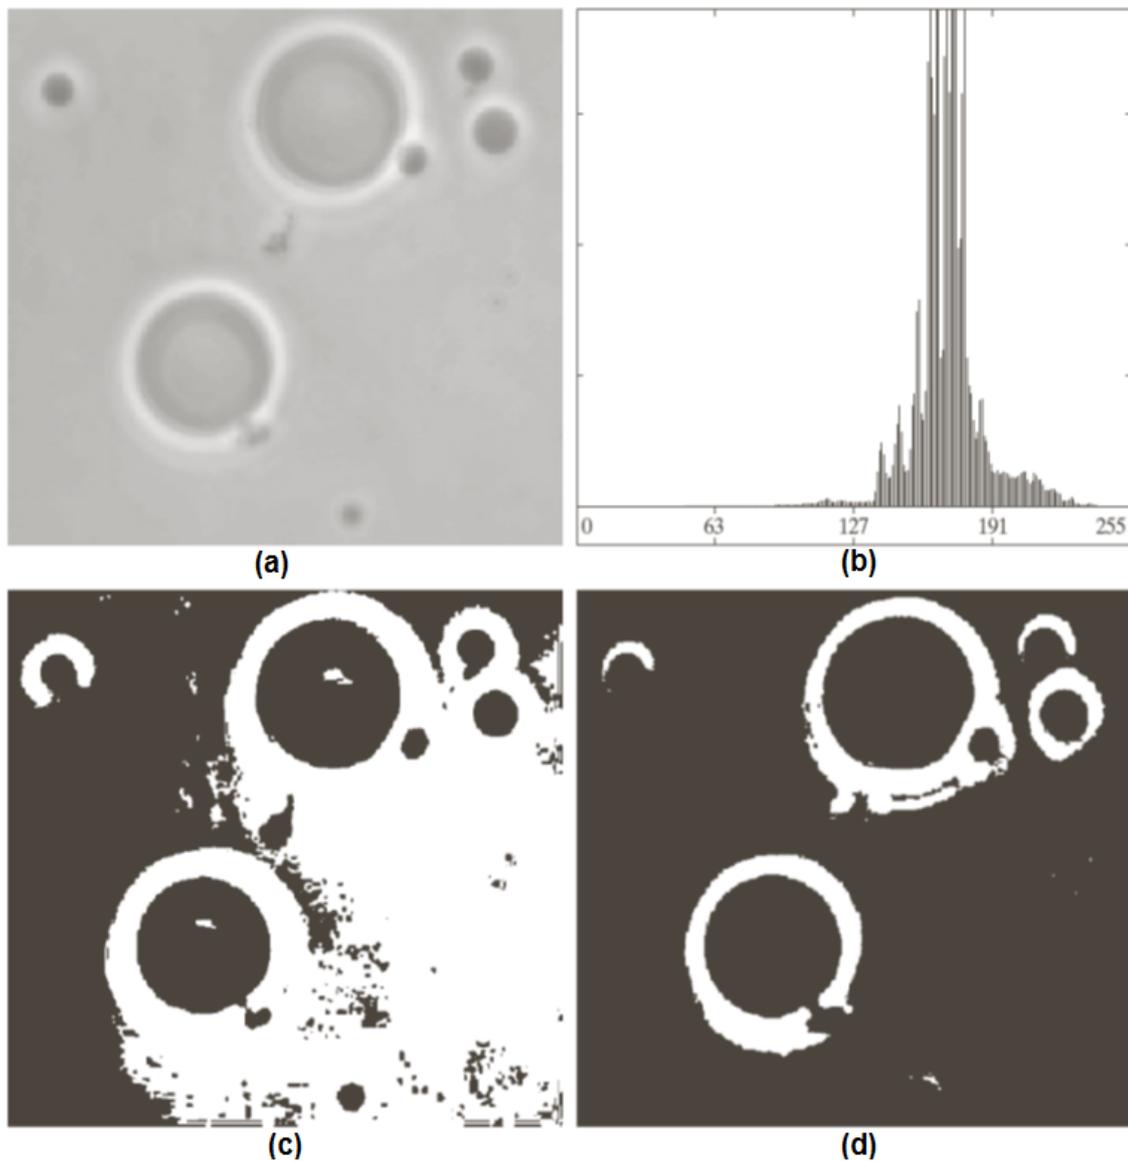


FIG. 7.2: (a) Image originale. (b) Histogramme. (c) Résultat de segmentation en utilisant l'algorithme global de base de la Section 7.3. (d) Résultat obtenu en utilisant la méthode d'Otsu.

7.5 Méthode de division/fusion (Split and merge)

7.5.1 Algorithme division/fusion

Soit R une image et Q un prédicat. L'approche consiste à subdiviser l'image en plusieurs régions R_i , telles que $Q(R_i) = TRUE$. On commence par une région entière. Si $Q(R) = FALSE$, on divise la région en quatre sous-régions et on continue pour chaque sous-région de manière récursive. Cette technique de décomposition a une représentation particulière sous

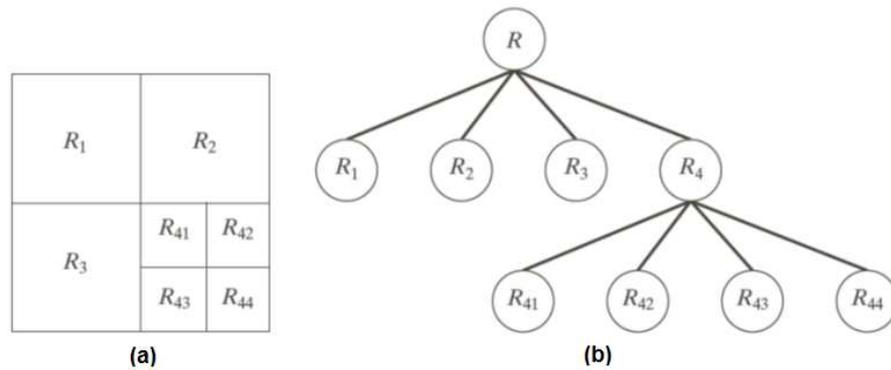


FIG. 7.3: Structure de représentation des décompositions de régions dans l'algorithme division/fusion. (a) Image partitionnée. (b) Le quadtree correspondant. R représente la région de l'image entière.

la forme de *quadtrees*, c'est-à-dire les arbres dans lesquels chaque nœud a exactement quatre fils, comme le montre la Fig. 7.3. Noter que la racine de l'arbre correspond à l'image entière et que chaque nœud correspond à la subdivision d'un nœud en quatre nœuds descendants. Dans ce cas, seul R_4 a été subdivisé. Une fois la décomposition achevée, fusionner chaque deux régions adjacentes R_i et R_j respectant la condition : $Q(R_i \cup R_j) = TRUE$. Arrêter quand aucune fusion de régions n'est possible.

La discussion précédente peut être résumée par la procédure suivante

- 1) Diviser en quatre quadrants disjoints toute région R_j , pour laquelle $Q(R_j) = FALSE$.
- 2) Lorsque aucune décomposition n'est possible, fusionnez les régions adjacentes R_j et R_k pour lesquelles $Q(R_j \cup R_k) = TRUE$.
- 3) Arrêtez lorsque aucune fusion n'est possible.

La Fig. 7.4(a) montre une image capturée en rayons X de la supernova Cygnus Loop. L'objectif de cet exemple est de séparer l'image de l'anneau de la matière entourant le centre. La région d'intérêt a des caractéristiques évidentes qui devraient contribuer à sa segmentation. Tout d'abord, noter que les données dans cette région ont une nature aléatoire, ce qui indique que son écart-type devrait être supérieur à l'écart type du fond (qui est près de 0) et de la grande région centrale, qui est assez lisse. De même, la valeur moyenne (intensité moyenne) d'une région contenant des données de l'anneau extérieur devrait être supérieure à la moyenne du fond plus foncé et inférieure à la moyenne de la grande région centrale plus claire. Ainsi, la région d'intérêt peut être segmentée en utilisant le prédicat suivant:

$$Q = \begin{cases} TRUE & \text{si } \sigma > a \quad \text{ET} \quad 0 < m < b \\ FALSE & \text{sinon} \end{cases} \quad (7.19)$$

où m et σ sont la moyenne et l'écart type des pixels en quadregion, et a et b sont des constantes.

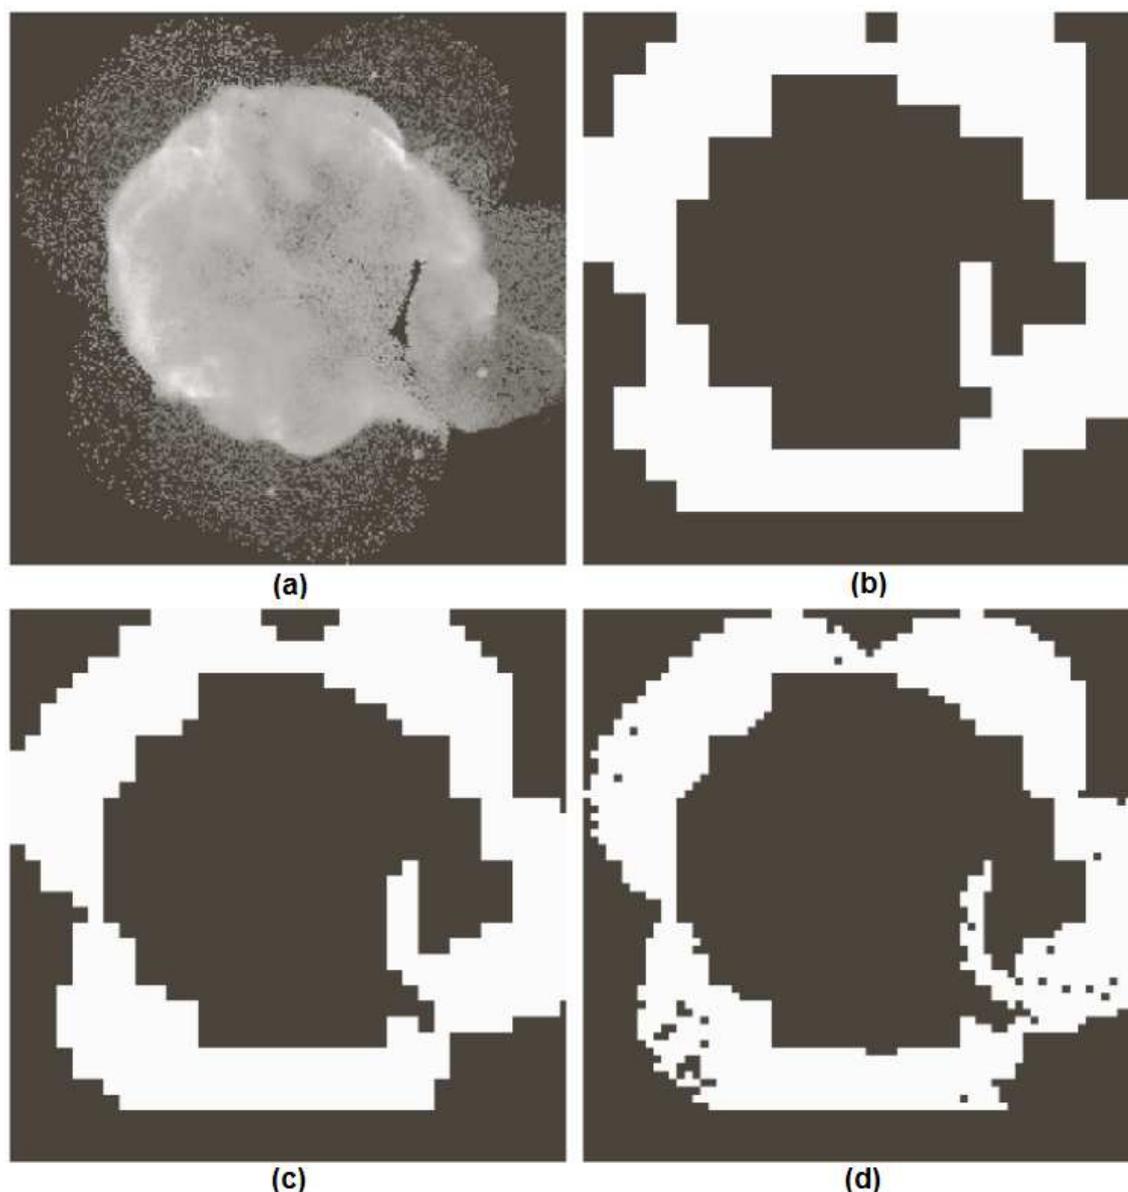


FIG. 7.4: (a) Image de la supernova, prise par le télescope Hubble de la NASA. (b)-(d) Résultats de la segmentation avec la méthode division/fusion en limitant la plus petite quadrégion à la taille de 32×32 , 16×16 et 8×8 pixels, respectivement.

Les Figs. 7.4(b) à (d) montrent les résultats obtenus en variant les constantes a et b , et en variant la taille minimale autorisée pour les quadrégions de 32 à 8. Les pixels dans une quadrégion qui satisfait le prédicat ont été mis en blanc et le reste des pixels de cette région étant mis en noir. Le meilleur résultat en termes de capture de la forme de la région externe a été obtenu en utilisant des quadrégions de taille 16×16 . Les carrés noirs de la Fig. 7.4(d) sont des quadrégions de taille 8×8 dont les pixels n'ont pas satisfait le prédicat. L'utilisation de petites régions entraînerait un nombre croissant de telles carrés noirs.

7.5.2 Remarques sur l'algorithme de division/fusion

- Avantages:
 - 1) Tient compte de l'information spatiale.
 - 2) Très simple à programmer.
 - 3) S'applique à un nombre arbitraire de régions.
- Inconvénients:
 - 1) Difficulté de définir un prédicat approprié.
 - 2) Produit des frontières de régions zigzagüées.

7.6 Méthode des K-moyennes (K-Means)

On suppose que chaque région est représentée par sa moyenne (de couleur ou de niveaux de gris). Ces moyennes représentent en général les centres des modes dans l'histogramme. Le problème est de rechercher ces moyennes. Ensuite, chaque niveau de gris sera assigné à la classe dont la moyenne est la plus proche.

7.6.1 Algorithme K-moyennes (K-Means)

- Soit K le nombre de régions dans l'image.
- Soit $\mu_1, \mu_2, \dots, \mu_K$ les moyennes (centres) de ces régions.
- Soit x_1, x_2, \dots, x_N les données de toute l'image.
 - 1) Initialiser $\mu_1, \mu_2, \dots, \mu_K$.
 - 2) Pour chaque donnée x_i : assigner x_i au centre k le plus proche.

$$r_{ik} = \begin{cases} 1 & \text{si } k = \operatorname{argmin}_j \|x_i - \mu_j\| \\ 0 & \text{sinon.} \end{cases} \quad (7.20)$$

- 3) Mettre à jour chaque centre μ_k comme suit:

$$\mu_k = \frac{\sum_{i=1}^N r_{ik} x_i}{\sum_{i=1}^N r_{ik}} \quad (7.21)$$

- 4) Si les centres restent stables, sortir, sinon, retourner à l'étape 2

Les Figs. 7.5(b)-(f) illustrent le résultat de la segmentation de l'image de la Fig. 7.5(a) avec différentes valeurs du paramètre K qui est le nombre de classes.

On peut également utiliser d'autres caractéristiques pour segmenter une image. On peut par exemple utiliser les caractéristiques liées à la texture.



FIG. 7.5: Illustration de la méthode K-means. (a) Image originale. (b)-(f) Résultat de la segmentation de l'image en (a) avec la méthode K-means avec le nombre de classes $K = 2, 8, 11, 14$ et 15 , respectivement.

Soit l'image texturée de la Fig. 7.6(a), il n'est pas impossible de segmenter cette image en deux classes sur la base exclusive des niveaux de gris car l'objet central possède le même histogramme que le reste de l'image.

On peut par exemple utiliser les dérivées en x et en y . De cette façon, chaque pixel (i, j) est associé à deux valeurs :

$$\left(\left| \frac{\partial I}{\partial x} \right|, \left| \frac{\partial I}{\partial y} \right| \right) \quad (7.22)$$

Maintenant que chaque pixel est associé à un point 2-D, il est facile de segmenter l'image à l'aide de l'algorithme des K-moyennes.

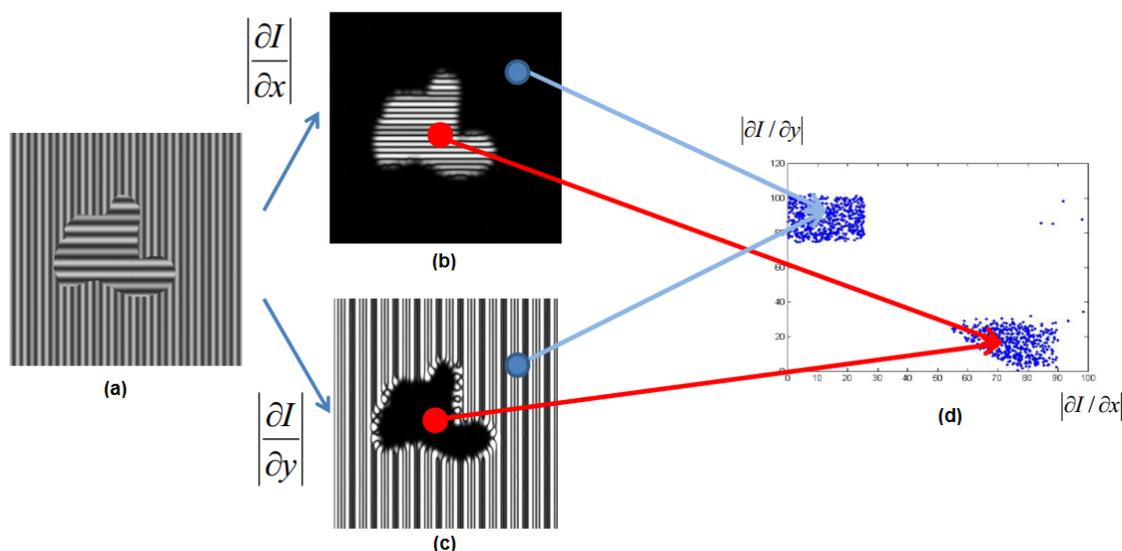


FIG. 7.6: Illustration de la méthode K-means pour une image texturée. (a) Image texturée avec deux classes. (b)-(c) Extraction des deux classes de l'image. (d) Représentation graphique des données de l'image sur un plan 2-D.

7.6.2 Remarques sur l'algorithme des K-moyennes

- Avantages:
 - 1) L'application aux images couleur n'ajoute pas une grande complexité.
 - 2) Très simple à programmer.
 - 3) S'applique à un nombre arbitraire de régions.
- Inconvénients:
 - 1) Ne contient pas l'information spatiale de l'image.
 - 2) Nombre de régions optimal difficile à déterminer automatiquement.

7.7 Méthode des contours actifs

7.7.1 Algorithme des contours actifs

Pour introduire l'information spatiale dans la segmentation, Kas et al.(1987) ont introduit la méthode des Snakes qui consiste à déformer une courbe initiale pour segmenter les frontières d'une région dans une image.

Une courbe paramétrique est définie comme suit (voir aussi la Fig. 7.7 pour une représentation graphique):

$$\begin{aligned} [0, 1] &\rightarrow \mathbb{R}^2 \\ t &\rightarrow \vec{C}(x(t), y(t)) \end{aligned} \quad (7.23)$$

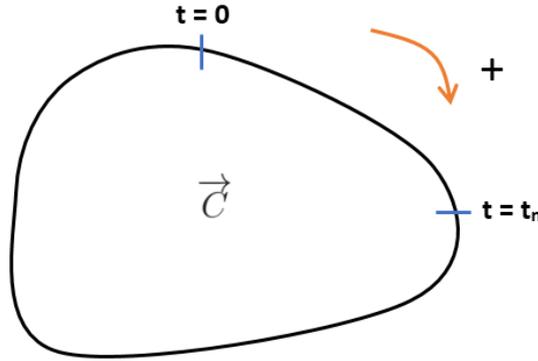


FIG. 7.7: Représentation graphique d'une courbe paramétrique.

La position finale de la courbe \vec{C} est obtenue en minimisant l'énergie suivante:

$$\begin{aligned} E(\vec{C}) &= E_{ext}(\vec{C}) + E_{int}(\vec{C}) \\ &= \alpha \int_0^1 g(\|\nabla I\|) dt + \beta \left[\int_0^1 \|\vec{C}'(t)\| + \|\vec{C}''(t)\| \right] \end{aligned} \quad (7.24)$$

où g est une fonction décroissante. L'énergie est minimisée par l'équation de *Euler-Lagrange*.

7.7.2 Limites de la méthode des contours actifs

- Sensibilité à l'initialisation.
- Changements topologiques (division/fusion) impossibles.

7.7.3 Algorithme des level-sets

Pour surmonter les limites des Snakes, la méthode des level-sets est proposée. Elle est formulée comme suit:

Soit N_0 l'ensemble des points de la courbe à déformer, et φ une fonction implicite définie comme suit:

$$\varphi(x, y) = \begin{cases} -d(x, y) & \text{si } (x, y) \text{ est à l'intérieur de } N_0 \\ 0 & \text{si } (x, y) \in N_0 \\ +d(x, y) & \text{si } (x, y) \text{ est à l'extérieur de } N_0 \end{cases} \quad (7.25)$$

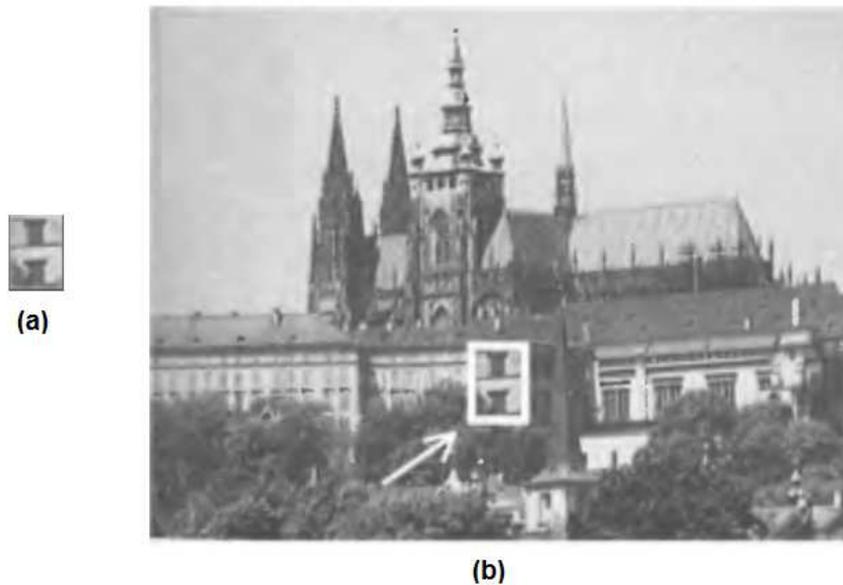


FIG. 7.8: Segmentation par correspondance (Matching). (a) Motif de référence de l'objet. (b) Image où il faut chercher l'objet.

Chan et Vese (2001) on introduit la fonction d'énergie suivante à minimiser:

$$E(\varphi) = \alpha \int_0^L ds + \beta \left[\iint_{R_{in}} |I - \mu_{in}| dx dy + \iint_{R_{out}} |I - \mu_{out}| dx dy \right] \quad (7.26)$$

où μ_{in} est la moyenne des niveaux de gris à R_{in} et μ_{out} est la moyenne des niveaux de gris à R_{out} . L'énergie est minimisée par l'équation de Euler-Lagrange.

7.8 Segmentation par correspondance (Matching)

Le problème consiste à localiser un objet à l'intérieur d'une image. Pour cela, on doit avoir un motif de l'objet qui va être la référence. Ce concept est illustré sur la Fig. 7.8.

7.8.1 Critères de recherche

On peut avoir plusieurs critères de recherche. Soit I l'image (de taille $N \times M$) et h le motif de l'objet (de taille $H \times W$).

- C_1 :

$$(x, y) \leftarrow \underset{(u,v)}{\operatorname{argmax}} \frac{\sum_{i=0}^{H-1} \sum_{j=0}^{W-1} I(u+i, v+j) \times H(i, j)}{\sum_{i=0}^{H-1} \sum_{j=0}^{W-1} I(u+i, v+j) \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} h(i, j)} \quad (7.27)$$

- C_2 :

$$(x, y) \leftarrow \operatorname{argmax}_{(u,v)} \frac{1}{1 + \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} [I(u+i, v+j) - h(i, j)]^2} \quad (7.28)$$

- C_3 :

$$(x, y) \leftarrow \operatorname{argmax}_{(u,v)} \frac{1}{1 + \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} |I(u+i, v+j) - h(i, j)|} \quad (7.29)$$

7.9 Conclusion

La segmentation d'image est une étape préliminaire essentielle dans la plupart des applications automatiques de reconnaissance de formes et d'analyse d'image. La décision du choix d'une technique de segmentation est prise selon le problème considéré. La liste des méthodes discutées dans ce chapitre, bien que loin d'être exhaustive, représente un échantillon des techniques utilisés en pratique. Dans le chapitre suivant de ce cours, nous allons étudier le concept de représentation d'image.