

# CLASIFICAREA METODELOR DE SEGMENTARE A IMAGINELOR DIGITALE DUPĂ MODURI DE ABORDARE ȘI TEHNICI DE UTILIZARE

Sergiu SCROB<sup>1\*</sup>,  
Inga LISNIC<sup>1</sup>

<sup>1</sup>Universitatea Tehnică a Moldovei, Facultatea Calculatoare, Informatică și Microelectronică, Departamentul Ingineria Software și Automatică, Doctorand, Chișinău, Republica Moldova

\*Autorul corespondent: Scrob Sergiu, e-mail: [sergiu.scrob@ati.utm.md](mailto:sergiu.scrob@ati.utm.md)

**Rezumat.** Metodele de segmentare a imaginilor digitale pot fi abordate prin două moduri: după detecția discontinuității și detecția similitudinii. Fiecare abordare descrie modul de acțiune pentru realizarea procesului de segmentare, iar în dependență de contextul problematic, rezultatele pot varia. La baza acestor abordări de segmentare stau tehnicile de segmentare, care reprezintă modul particular care descrie totalitatea procedurilor de segmentare care pot fi aplicate la o metodă dintr-un domeniu specific de cercetare. Printre cele mai populare tehnici de segmentare se disting tehnicile: structurale, stocastice și hibride. Iar tehnicile de segmentare contribuie la rândul lor la formarea metodelor de segmentare care reprezintă ansamblu de procedee folosite în realizarea unui scop mai general de segmentare pentru identificarea unei soluții generale din contextul problematic general. Printre cele mai populare metode de segmentare se cunosc metodele bazate pe: contur, histogramă, regiuni, dividere și fuziuni, clusterizare, rețele neuronale, structura morfologică și analiza semantică. Din metodele de segmentare se pot forma modele de segmentare care constituie ansamblu de algoritmi concreți dezvoltați pentru realizarea unei sarcini concrete.

**Cuvinte cheie:** abordări în segmentare, tehnici de segmentare, metode de segmentare, clasificarea metodelor de segmentare.

## Introducere

Procesarea imaginilor digitale este o parte vitală a procesului de analiză și prelucrare a datelor în domeniul Computer Vision. Acest domeniu se referă la extragerea de informații utile din imagini de către un calculator în mod nesupervizat sau parțial cu intervenția umană. Sistemele dotate cu vedere artificială și vizualizare computerizată depind direct de algoritmi și metodele de procesare a imaginilor digitale care stau la baza acestor sisteme, iar în dependență de modul de funcționare ne permite să obținem o precizie cât mai înaltă a rezultatelor. Utilizarea rețelilor neuronale depășesc alte abordări metodice cu o marjă mai mare în ceea ce privește acuratețea și eficiența rezultatelor. O bună parsare a imaginilor poate avea implicații în diverse domenii fiind utilă pentru recunoașterea obiectelor, imagistică medicală și asistarea unui diagnostic medical, modelarea 3D a scenelor urbane, sisteme de asistență digitală pentru oameni cu recunoașterea amprentei, vocii sau a retinei, asistarea vehiculelor și dispozitivelor autonome în luarea unei decizii bazate pe recunoașterea obiectelor, fenomenelor și altor acțiuni în timp real. Principalul obiectiv al segmentării este reprezentarea unei imagini într-un mod semnificativ și ușor de analizat.

Una dintre marile provocări ale acestei ramuri, care continuă să fie încă foarte actuală la moment este extragerea și recunoașterea obiectelor și entităților de interes specific sau general din imaginile digitale. Această provocare este constant abordată prin cercetarea și implementarea a noi metode și modele de segmentare a imaginilor digitale, care au scopul de a optimiza și genera rezultate cât mai bune, dar și pentru a identifica o soluție unică pentru diverse domenii de aplicare.

## Clasificarea metodelor de segmentare a imaginilor digitale


Modelele de segmentare a imaginilor digitale se bazează pe una sau mai multe metode de segmentare, la baza cărora se află tehnicile de segmentare care de asemenea se bazează pe diverse

moduri de abordare. Fiecare abordare, tehnică și metodă de segmentare are avantajele și dezavantajele sale, iar în dependență de cazurile de utilizare a acestor metode în practică, putem observa că unele metode pot genera rezultate mai bune într-un caz concret iar altele pot genera rezultate mai slabe. Există două moduri de abordare în segmentarea imaginilor pe baza proprietăților imaginii:

1. Abordarea bazată pe detecția discontinuității. Aceasta este abordarea în care o imagine este segmentată în regiuni bazate pe discontinuitate. Segmentarea bazată pe detectarea marginilor se încadrează în această categorie în care sunt detectate marginile formate din cauza întreruperii intensității și legate de limitele de formă ale regiunilor [1].
2. Abordarea bazată pe detectarea similitudinii. Aceasta este abordarea în care o imagine este segmentată în regiuni bazate pe similaritate. Tehnicile care se încadrează în această abordare sunt: tehnici de prag, tehnici de creștere a regiunii și divizare și îmbinare a regiunilor. Toate împărțesc imaginea în regiuni cu un set similar de pixeli. Tehnicile de clustering folosesc și această metodologie. Acestea împart imaginea în set de clustere având caracteristici similare bazate pe unele criterii predefinite [1, 2]. Cu alte cuvinte, putem spune că segmentarea imaginii poate fi abordată din trei perspective: abordarea regiunii, abordarea muchiei și clustering de date. Abordarea regiunii se află sub detecție de similitudine și detecție de margine iar detecție de graniță se află sub detecție de discontinuitate. Tehnicile de clustering se află, de asemenea, în detecție de similaritate.

Există mai multe tehnici de segmentare a imaginii, care repartizează imaginea în mai multe părți, bazate pe anumite caracteristici ale imaginii, cum ar fi valoarea intensității pixelilor, culoarea, textura, etc. Aceste tehnici sunt clasificate în funcție de metoda de segmentare folosită și abordează una sau poate ambele moduri descrise mai sus. Toate aceste tehnici au algoritmul lor și pot fi abordate din două abordări de bază ale segmentării, adică abordări bazate pe regiune sau pe margine. Fiecare tehnică poate fi aplicată pe imagini diferite pentru a realiza segmentarea necesară. Toate aceste tehnici pot fi clasificate în trei categorii:

1. **Tehnici de segmentare structurală.** Tehnicile structurale sunt acele tehnici de segmentare care se bazează pe informațiile despre structura porțiunii necesare a imaginii, adică regiunea necesară care urmează să fie segmentată, această tehnică reprezintă o segmentare bazată pe regiuni. Metodele de detectare a regiunilor folosesc similitudinea și proximitatea spațială între pixeli pentru determinarea regiunilor. Putem distinge:
  - metode de creștere a regiunilor, se alege poziția unui pixel și se caută în cele 8 direcții dacă pixelii vecini corespund unui criteriu de similaritate, formând astfel regiuni omogene [3,4];
  - metode de dividere și fuziunea regiunilor (Splitting and Merging) [5]. Scopul este de a împărți imaginea în regiuni, fiecare dintre care este omogenă în un anumit sens, dar unirea a două regiuni adiacente numai este omogenă în același sens.
  - metode bazate pe contur [6,7] atunci când o regiune este definită ca un set de pixeli, delimitate de un contur de culoare. Pentru determinarea conturilor este importantă rata de variație a nivelelor de gri (a valorilor pixelilor de culoare).
2. **Tehnici de segmentare stocastică.** Tehnicile stocastice sunt acele tehnici de segmentare a imaginii care funcționează pe valorile discrete ale pixelilor imaginii în loc de informațiile structurale ale regiunii. Această tehnică reprezintă o segmentare bazată pe pixel, unde o regiune este definită ca un set de pixeli ce au aproximativ aceeași intensitate luminoasă/culoare. Putem distinge:
  - metode bazate pe histogramă [8];
  - metode de clusterizare [9];
  - metode fuzzy de clusterizare [10].
3. **Tehnici hibride.** Tehnicile hibride sunt acele tehnici de segmentare a imaginii care folosește conceptele ambelor tehnici de mai sus, adică acestea folosesc împreună atât informații structurale cât și valorile discrete ale pixelilor.



**Figura 1 - Clasificarea metodelor de segmentare a imaginilor digitale**

Segmentarea semantică cu ajutorul rețelelor neuronale ne poate ajuta să localizăm și să identificăm câte mai multe obiecte. Majoritatea algoritmilor de segmentare semantică utilizează rețelele neuronale deoarece sunt cele mai capabile să învețe. Dar din cauza limitelor impuse de capacitatea de calcul la moment, acești algoritmi oferă o detalizare minimă din potențialul maxim disponibil.

### Concluzii

La momentul actual nivelul de segmentare a imaginilor digitale oferă o detalizare minimă, și abordează intenționat o procedură de segmentare simplificată pentru a spori viteza de procesare, dar sacrificând în schimb o parte din informație pe care ar putea să o analizeze pentru a identifica mai multe obiecte. Segmentarea semantică ar putea oferi mai multe informații și nu doar de a analiza culorile și intensitatea lor pentru a delimita și eticheta obiectele, dar și pentru a putea localiza și analiza obiectele după mulți alți parametri precum: dimensiune, spațiu, timp, stare, formă, înveliș, poziție, direcție, relație, concepte și structura morfologică. Segmentarea semantică

bazată pe rețele neuronale de tip convoluțional este una dintre cele mai productive tipuri de segmentare la momentul actual, dar care nu are încă la bază un model universal pentru procesarea imaginilor cu conținut diversificat din diferite domenii.

O soluție optimă ar fi dacă ar exista un singur model de segmentare bazat pe o singură arhitectură de rețea neuronală pentru toate cazurile. Ar fi mai potrivit să analizăm fiecare detaliu din imagine altfel încât să obținem o detalizare cât mai mare cu cât mai multe obiecte. Iar fiecare obiect ar putea avea relație cu alte obiecte din care am putea deduce un alt obiect ce încapsulează obiecte mai mici. Cu toate că o astfel de abordare ar crește complexitatea computațională și ar reduce din viteza de procesare.

Domeniul Inteligenței Artificiale, Viziunii Computerizată și Agenților Inteligenți necesită un model de segmentare cât mai performant, unde procesul de segmentare să ofere maximă detalizare și nu doar viteză înaltă de procesare. Aceste domenii depind în mod direct de procesul de segmentare, parte din procesarea imaginii, deoarece asta ar putea constitui un model de percepție prin care ar avea loc asimilarea informației în volumul cât mai amplu care este atât de necesar în orice misiune.

### Referințe

1. Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing, 2nd ed.*, Beijing: Publishing House of Electronics Industry, 2007.
2. T. Shraddha, K. Krishna, B.K. Singhand, R.P. Singh. Image Segmentation: A Review. In: *International Journal of Computer Science and Management Research*. 2012. pp. 838-843.
3. Deng Y., Manjunath B. S., Shin H. Color image segmentation. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol. 2. 1999 p. 446-451.
4. Shih F.Y., Cheng S. Automatic seeded region growing for color image segmentation. In: *Image and Vision Computing*. Vol. 23. 2005. p. 877-886.
5. Liu L., Sclaroff S. Region segmentation via deformable model-guided split and merge. In: *Proc. Eighth IEEE International Conference on Computer Vision*. Vol.1. 2001. p. 98-104.
6. Ma W.Y., Manjunath B. S. EdgeFlow: A technique for boundary detection and image segmentation. In: *IEEE Transactions on Image Processing*. Vol. 9. 2000, p. 1375-1388.
7. Rao S. R. and al. Natural image segmentation with adaptive texture and boundary encoding. In: *The 9th Asian conference on Computer Vision*. Vol. 1. 2009. p.135-146.
8. Suryanto, Kim D.H., Kim H.K., Ko S.J. Spatial color histogram based center voting method for subsequent object tracking and segmentation. In: *Image and Vision Computing*. Vol.29. 2011. p. 850-860.
9. Bong C.W., Rajeswari M. Multi-objective nature-inspired clustering and classification techniques for image segmentation. In: *Applied Soft Computing*, Vol.11. 2011. p. 3271-3282
10. Chien B.C., Cheng M.C., A color image segmentation approach based on fuzzy similarity measure. In: *Proceedings of the 2002 IEEE International Conference on Fuzzy Systems*. Vol.1. 2002. p. 449-454.