

# Segmentarea și Regularizarea MAP-Markov a Imaginilor Satelitare

- lucrare de laborator -

șl.dr.ing. Șerban OPRIȘESCU

În această lucrare vom aborda domeniul segmentării imaginilor satelitare și al îmbunătățirii rezultatului segmentării (operație numită regularizare) utilizând metoda MAP-Markov.

## 1) Modelarea Gaussiană a categoriilor rurale

**Segmentarea imaginilor** constă în descompunerea unei scene (imagini) în componentele sale [1][2]. Aceste componente trebuie să fie mulțimi disjuncte, nevide și conexe. În urma procesului de segmentare vor fi extrase din imagine regiuni ce satisfac anumite criterii de uniformitate, sau alte elemente.

Obiectivul este de a rezuma informația prezentă într-o imagine observată, așa încât **numărul de clase prezente în imaginea segmentată să fie foarte mic** în raport cu valorile observate în imagine. Imaginea astfel obținută permite o prezentare compactă și ușor exploatabilă a datelor.

### Modelul imaginii satelitare utilizat

Notăm cu  $E = \mathbf{R}^N$  spațiul stărilor corespunzând la  $N$  benzi de frecvență. O imagine hiperspectrală  $S$ , formată din  $M$  pixeli  $s$ , poate fi reprezentată ca un punct în spațiul  $E^M$ .

Notăm cu  $\mathbf{Y} = (Y_{S1}, \dots, Y_{SM})$  câmpul aleator asociat imaginii  $S$  și cu  $\mathbf{y} = (y_{S1}, \dots, y_{SM}) \in E^M$  o realizare a lui  $\mathbf{Y}$ .

Fie  $\Lambda$  mulțimea celor  $K$  clase ce sunt folosite ca etichete pentru pixelii din  $S$ . Notăm cu  $\mathbf{X} = (X_{S1}, \dots, X_{SM})$  câmpul aleator care exprimă procesul de clasificare și cu  $\mathbf{x} = (x_{S1}, \dots, x_{SM}) \in \Lambda^M$  o configurație a imaginii  $S$ .

*Repartiția a priori* pe spațiul configurațiilor este o repartiție discretă, ce se notează cu  $P(\mathbf{X}=\mathbf{x})$ .

Repartiția de probabilitate a lui  $\mathbf{Y}$  pentru o configurație dată (condiționată de o configurație dată), notată  $P(\mathbf{Y}|\mathbf{X}=\mathbf{x})$ , este exprimată prin *densitatea condiționată de probabilitate*  $f(\mathbf{y}|\mathbf{X}=\mathbf{x})$ .

Utilizând formula lui Bayes, se poate determina *repartiția de probabilitate a posteriori* pentru configurațiile  $\mathbf{x}$ , dată fiind o realizare  $\mathbf{y}$  a lui  $\mathbf{Y}$  în spațiul stărilor:

$$P(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y}) = \frac{f(\mathbf{y} | \mathbf{X} = \mathbf{x})P(\mathbf{X} = \mathbf{x})}{\sum_{\mathbf{x}} f(\mathbf{y} | \mathbf{X} = \mathbf{x})P(\mathbf{X} = \mathbf{x})} \quad (1)$$

Mai explicit, imaginile satelitare sunt de obicei multispectrale, de exemplu o imagine furnizată de satelitul Spot 4 este o matrice lin x col x  $N$ , unde  $N=4$  benzi spectrale.

O imagine color clasică are doar 3 benzi spectrale (roșu,verde,albastru), adică o imagine de 1Mpixel preluată cu o cameră web simplă este o matrice tridimensională:  $648 \times 480 \times 3$ .

### Modelare Gaussiană a categoriilor rurale

Modelul statistic tradițional al unei categorii rurale este cel al repartiției Gaussiene multidimensionale (în spațiul stărilor  $E = \mathbf{R}^N$ ). Astfel, pentru o clasă  $x$  (categorie rurală), densitatea condiționată de repartiție  $f(\mathbf{y}|\mathbf{X} = x)$  pe spațiul stărilor  $E = \mathbf{R}^N$  are forma

$$f(\mathbf{y} | \mathbf{X} = x) = \frac{1}{\sqrt{(2\pi)^N \det \Sigma_x}} \exp\left(-\frac{1}{2}(\mathbf{y} - \mu_x)^t \Sigma_x^{-1} (\mathbf{y} - \mu_x)\right), \quad (2)$$

adică avem un model Gaussian  $N(N; \mu_x, \Sigma_x)$ . Pentru cazul când numărul claselor  $x \in \Lambda$  este  $K$ , avem la dispoziție o familie de repartiții gaussiene,  $\{N(N; \mu_x, \Sigma_x), x \in \Lambda\}$ .

Semnificația parametrilor este următoarea:

$$E(\mathbf{Y} | \mathbf{X} = x) = \mu_x \quad \text{și} \quad \text{Cov}(\mathbf{Y} | \mathbf{X} = x) = \Sigma_x$$

## 2. Instruirea clasificatorului prin estimare directă

Estimarea statistică directă poate fi aplicată pentru instruirea (sau învățarea, sau antrenarea) clasificatorului dacă dispunem de un „adevăr teren” (*ground truth*), adică de o porțiune cunoscută a imaginii care conține toate categoriile de teren.

Neglijând indexul de clasă, forma densității de repartiție ai cărei parametri trebuie estimați este:

$$f(y; \mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^N \det \Sigma}} \exp\left(-\frac{1}{2}(y - \mu)^t \Sigma^{-1}(y - \mu)\right), \quad (3)$$

unde  $\mu \in \mathbf{R}^N$ , iar  $\Sigma$  este o matrice simetrică, pozitiv definită, de dimensiune  $N \times N$ . Estimarea parametrilor modelului se realizează prin metoda verosimilității maxime.

Presupunem că dispunem de un adevăr teren și notăm cu  $Y_1, \dots, Y_n$  cei  $n$  vectori ai observațiilor corespunzătoare pixelilor din fereastra de învățare. Fie  $\mathbf{Y} = (Y'_1, \dots, Y'_n)'$  vectorul aleator corespunzător și fie  $\mathbf{y} = (y'_1, \dots, y'_n)'$  vectorul observațiilor.

Funcția de verosimilitate este egală cu densitatea de repartiție a lui  $\mathbf{Y}$  calculată în  $\mathbf{y}$ ,

$$L(\mu, \Sigma) = g(\mathbf{y}; \mu, \Sigma) = \prod_j f(y_j; \mu, \Sigma)$$
$$L(\mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^{N \cdot n} (\det \Sigma)^n}} \exp\left(-\frac{1}{2} \sum_j (y_j - \mu)^t \Sigma^{-1} (y_j - \mu)\right), \quad (4)$$

Estimația de verosimilitate maximă este soluția problemei de optimizare  $\text{Max } \{ L(\mu, \Sigma) \}$ .

## 3. Simularea unei imagini satelitare

„Imaginea de lucru” pentru orice procedură de regularizare este o imagine satelitară segmentată. Etapele în care am generat o asemenea imagine de lucru au fost:

- Generarea cu calculatorul a imaginii „adevăr teren”;
- Obținerea „imaginii satelitare” prin perturbarea imaginii „adevăr teren” cu un zgomot aleator;
- Segmentarea imaginii satelitare, prin metoda MAP

### Imaginea „adevăr teren”

S-a urmărit obținerea unei imagini de tipul celor ce se întâlnesc în problemele de Land-Use, deci regiunile au fost bine delimitate prin frontiere drepte sau curbe.

S-au folosit 5 tipuri de clase ( $K=5$ ), fiecărei clase fiindu-i asociată o anumită culoare din spațiul RGB, iar fiecare regiune disjunctă fiind colorată uniform cu una din cele 5 culori.

Menționăm că imaginea a fost generată folosind un program de desen, și este o imagine RGB clasică (formată din 3 benzi).

Imaginea generată și utilizată apoi în studiu este prezentată în Fig. 1.

Această imagine va fi folosită ca imagine de referință în evaluarea rezultatului metodelor de regularizare.

**b) Imaginea satelitară** s-a obținut prin perturbarea imaginii „adevăr teren” cu un zgomot aleator.




Fig. 1. Imaginea "adevăr teren"

#### 4. Segmentare MAP pentru zonele rurale

Fie  $E = \mathbf{R}^N$  spațiul stărilor corespunzând la  $N$  benzi de frecvență,  $S$  o imagine hiperspectrală formată din  $M$  pixeli și  $E^M$  spațiul stărilor corespunzând imaginilor formate din câte  $M$  pixeli.

Fie  $\Lambda$  mulțimea celor  $K$  clase ce sunt folosite ca etichete pentru pixelii din  $S$ .

Notăm cu  $\mathbf{X}$  câmpul aleator ( $\Lambda^M$ ,  $P(\Lambda^M)$ ,  $P$ ) corespunzător imaginilor formate din câte  $M$  pixeli care vor fi reprezentate prin configurații ce utilizează mulțimea claselor  $\Lambda$ .

Notăm cu  $\mathbf{y} \in E^M$  vectorul stărilor corespunzând unei imagini  $S$  observate. **Imaginea segmentată** este definită de o configurație  $\mathbf{x} = (x_{s1}, \dots, x_{sM}) \in \Lambda^M$ .

Notăm cu  $P(\mathbf{X}=\mathbf{x})$  probabilitatea a priori a configurației  $\mathbf{x}$  și cu  $P(\mathbf{X}=\mathbf{x}|\mathbf{Y}=\mathbf{y})$  probabilitatea Bayesiană (a posteriori) a configurației  $\mathbf{x}$ , cunoscând vectorul observat al stărilor,  $\mathbf{y}$ . Ambele sunt repartiții de probabilitate pe spațiul configurațiilor.

**O imagine MAP segmentată** este definită de configurația ce se obține ca soluție a următoarei probleme de optimizare:

$$\mathbf{x}^* = \arg \max P(\mathbf{X}=\mathbf{x}|\mathbf{Y}=\mathbf{y}) = \arg \max (f(\mathbf{y}|\mathbf{X}=\mathbf{x})P(\mathbf{X}=\mathbf{x})), \quad (5)$$

Logaritmând, putem transforma problema de găsire a maximumului într-una de găsire a minimumului, de forma:

$$\mathbf{x}^* = \arg \min (-\ln f(\mathbf{y}|\mathbf{X}=\mathbf{x}) - \ln P(\mathbf{X}=\mathbf{x})) \quad (6)$$

**Ipoteza de bază** a metodei MAP este **independența condiționată** a pixelilor în spațiul stărilor:

$$f(\mathbf{y}|\mathbf{X}=\mathbf{x}) = \prod_{s \in S} f(y_s | X_s = x_s) \quad (7)$$

Într-o primă aproximare, configurațiile  $\mathbf{x}$  sunt echiprobabile, adică  $P(\mathbf{X}=\mathbf{x})$  este repartiția uniformă (**ipoteza repartiției uniforme pentru configurații**):

$$P(\mathbf{X}=\mathbf{x}) = \prod_{s \in S} P(X_s = x_s) = 1 / K^M \quad (8)$$

Această ipoteză exprimă de fapt necunoașterea adevăratei repartiții a priori, sau faptul că aceasta ne este inaccesibilă.

În ipotezele de mai sus, o configurație MAP,  $\mathbf{x}^* = (x_{s1}^*, \dots, x_{sM}^*)$ , poate fi obținută prin rezolvarea unor probleme de **optimizare locală**.

Pentru fiecare pixel  $s$ , se rezolvă problema

$$x_{s}^* = \arg \max \{f(y_s | X_s = x_1), \dots, f(y_s | X_s = x_{K-1}), f(y_s | X_s = x_K)\} \quad (9)$$

sau

$$x_{s}^* = \arg \min \{-\ln f(y_s | X_s = x_1), \dots, -\ln f(y_s | X_s = x_{K-1}), -\ln f(y_s | X_s = x_K)\} \quad (10)$$

Vom considera modelarea Gaussiană a categoriei rurale, ceea ce revine la utilizarea modelelor Gaussiene în spațiul stărilor. Densitatea de repartiție condiționată corespunzătoare este

$$f(y_s | X_s = x) = \frac{1}{(2\pi)^{N/2} (\det \Sigma_x)^{1/2}} \exp\left(-\frac{1}{2}(y_s - \mu_x)^T \Sigma_x^{-1} (y_s - \mu_x)\right),$$

Găsirea clasificatorului MAP revine la maximizarea densității de repartiție a posteriori

$$x_{s}^* = \arg \max \{f(y_s | X_s = x_s)\} \quad (11)$$

În continuare, se introduce noțiunea de **funcție de energie**  $U(\mathbf{x})$ , dată de log-verosimilitatea unei configurații  $(x_s)_s$  în raport cu observațiile  $(y_s)_s$

$$U(\mathbf{x}) = (\mathbf{y}_s - \mu_x)^T \Sigma_x^{-1} (\mathbf{y}_s - \mu_x) + \ln (\det \Sigma_x) \quad (12)$$

Această funcție de energie ar trebui să modeleze toate fenomenele de degradare a obiectului inițial în timpul procesului de observare.

Găsirea clasificatorului MAP revine, echivalent, la minimizarea funcției de energie,

$$\mathbf{x}_s^* = \arg \min ((\mathbf{y}_s - \mu_x)^T \Sigma_x^{-1} (\mathbf{y}_s - \mu_x) + \ln (\det \Sigma_x)) \quad (13)$$

## 5. Regularizare MAP-Markov pentru zone rurale

Segmentarea folosind câmpul Gibbs, introdusă în 1987 ([3]), a devenit una dintre cele mai importante și mai utilizate metode de regularizare. În această abordare, clasa atribuită unui pixel depinde nu numai de caracteristicile spectrale ale pixelului, ci și de caracteristicile spectrale ale vecinilor săi.

**Regularizarea MAP-Markov** se realizează lucrând în ipoteza că  $\mathbf{X}$  este un câmp Markov pe  $S$ , cu sistemul de vecinătăți  $V_s$ .

Conform acestei ipoteze și conform teoremei Hamersley – Clifford, repartiția  $P(\mathbf{X}=\mathbf{x})$  este repartiția Gibbs.

Notăm cu  $C$  familia clicelor corespunzătoare sistemului de vecinătăți  $V_s$ , cu  $U_c(\mathbf{x})$  energia clicii  $c \in C$ , și cu

$$U(\mathbf{x}) = \sum_{c \in C} U_c(\mathbf{x}) \quad (14)$$

energia totală a configurației  $\mathbf{x}$ .

Repartiția Gibbs este dată de  $P(\mathbf{X}=\mathbf{x}) = Z^{-1} \exp(-\sum_{c \in C} U_c(\mathbf{x}))$ , unde  $Z$  este constanta de normalizare.

**O imagine MAP-Markov regularizată** este soluția următoarei probleme de optimizare:

$$\mathbf{x}^{**} = \arg \max \{f(\mathbf{y}|\mathbf{X}=\mathbf{x}) \exp(-U(\mathbf{x}))\} \quad (15)$$

Ca și în etapa de segmentare, se face **ipoteza independenței condiționate** a pixelilor. Astfel, soluția  $\mathbf{x}^{**}=(x^{**}_{s_1}, \dots, x^{**}_{s_M})$  se poate obține prin rezolvarea unor probleme locale de optimizare,

$$x^{**}_s = \arg \max \{f(y_s|X_s = x_1) \exp(-U(x_1)), \dots, f(y_s|X_s = x_K) \exp(-U(x_K))\} \quad (16)$$

### Definirea energiei clicilor

Definirea lui  $U(\mathbf{x})$  depinde de sistemul de vecinătăți  $V_s$  și de contribuția clicelor la expresia probabilităților a posteriori  $P(\mathbf{X}=\mathbf{x}|\mathbf{Y}=\mathbf{y})$ .

Modelul cel mai utilizat pentru definirea energiei este modelul Potts, în care se consideră ca fiind “active” doar clicile de ordinul 2. Acest model provine din mecanica cuantică (Chandler 1987), mai precis este o variantă a modelului Ising, folosit pentru descrierea orientării spinilor.

Energia totală a configurației  $\mathbf{x}$  este dată de expresia

$$U(\mathbf{x}) = \beta \sum \delta(x_s, x_t), \quad (17)$$

unde suma se face după toate clicile de ordinul doi  $c_2 = \{s, t\}$ ,  $\beta > 0$ , iar

$$\delta(x_s, x_t) = -1 \text{ dacă } x_s = x_t, \text{ și } \delta(x_s, x_t) = 1 \text{ dacă } x_s \neq x_t \quad (18)$$

Rezultă că problema locală de optimizare ce trebuie rezolvată pentru fiecare pixel  $s$  este

$$x^{**}_s = \arg \max \{f(y_s|X_s = x_s) \exp(-\beta \sum_t \delta(x_s, x_t))\} \quad (19)$$

O valoare mare a lui  $\beta$  favorizează reclasarea unui pixel izolat în clasa cea mai frecvent întâlnită pentru vecinii lui. Valoarea  $\beta=0$  ne readuce la “clasificarea prin verosimilitate maximă”.

## 6. Desfășurarea lucrării

1. Încărcați o imagine de test de tip adevăr teren, de exemplu test1.bmp:

```
img = imread('test1.bmp');
```

Imaginea se afișează cu:

```
figure, image(img);
```

2. Adăugarea de zgomot alb gaussian de medie zero și dispersie D pe imagine, pentru a simula o imagine satelitară:

```
help addnoise
```

```
img = addnoise(img, 'gaussian', D);
```

Imaginea se afișează cu:

```
figure, image(img);
```

3. Segmentarea și regularizarea imaginii simulate mai sus:

```
help segreg
```

```
[seg reg] = segreg(img, beta, iter);
```

Alegeți diferite valori ale parametrului de reglaj al regularizării (beta) și a numărului de iterații a regularizării (iter).

Repețați segmentarea – regularizarea cu o imagine tip satelitar mai zgomotoasă (dispersie D mai mare). Ce observați?

4. Segmentarea și regularizarea MAP-Markov a unei porțiuni dintr-o imagine satelitară reală \*

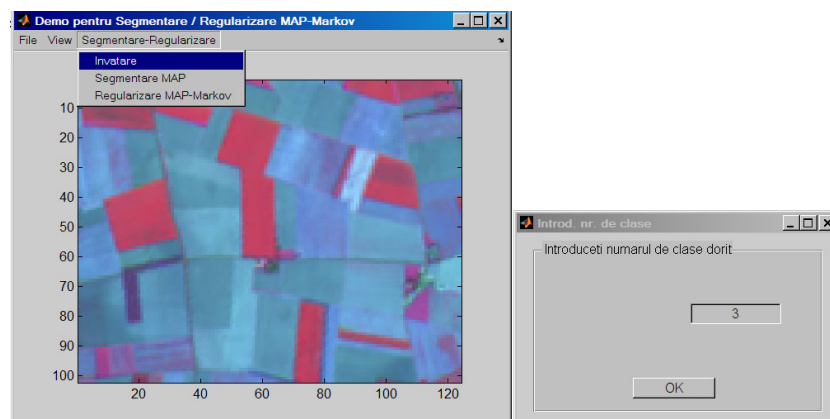
```
help demo_sr
```

Programul demonstrativ demo\_sr permite următoarele prelucrări succesive:

- a) Deschiderea imaginii satelitare folosind meniul File -> Load
- b) Învățarea parametrilor claselor (medie și matrice de covarianță) comandată din meniul: Segmentare-Regularizare -> Învățare
- c) Segmentarea imaginii satelitare cu selecțiile de „adevăr teren” învățate la pasul b)
- d) Regularizarea imaginii segmentate anterior.

Deschideți imaginea „test1\_B4.BMP” și urmați pașii b) – d)

Selectarea fiecărei zone de învățare se face apăsând lupa și selectând cu mouse-ul doar mica zonă dreptunghiulară ce conține pixelii aparținând unei singure clase. După fiecare selectare zona afișabilă a ferestrei trebuie să conțină doar pixelii selectați (zoom). Apoi, se revine cu lupa de micșorare la dimensiunea originală (zoom out) și se alege zona următoare.



\*Codul sursă al funcțiilor necesare acestei lucrări de laborator, împreună cu acest îndrumar se găsesc pe pagina personală a autorului:

<http://imag.pub.ro/~soprisescu>

Bibliografie:

- [1] Opreșescu S. (2007), „Metode avansate de modelare statistică pentru segmentarea imaginilor satelitare în zone urbane, rurale și mixte”, teză de doctorat, UPB.
- [2] Jain V., (1989), *Fundamentals of image processing*, Prentice Hall
- [3] Derin H. and Elliott H., (1987), “Modeling and segmentation of noisy and textured images using Gibbs random fields”, *IEEE. Trans. on Pattern Anal. and Mach. Intell.*, 9, pp.721–741

**Lucrare elaborată de sl.dr.ing, Șerban Opreșescu, 07 aprilie 2015**