


SEGMENTAREA IMAGINILOR

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Segmentarea = descompunerea imaginii in partile sale componente.

(reducerea numarului de culori dintr-o imagine este un caz particular)

Segmentare :

- orientata pe regiuni
- orientata pe contururi

(abordari duale)

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR









imagine originală




imagine segmentată
(imagine de etichetă)





C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Segmentare

Descompunerea imaginii (scenei) in partile sale constituyente.

Matematic: segmentarea este o partitionare a multimii pixelilor din imaginea f , in submultimi f_i continand una sau mai multe componente conexe, disjuncte si uniforme dpdv al unui criteriu C pre-stabilit.

$$f = \bigcup_i f_i$$

$$f_i \cap f_j = \phi, i \neq j$$

$$C(f_i) = 1$$

$$C(f_i \cup f_j) = 0$$

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Erori :


supra-segmentarea :

descompunerea imaginii in mai multe elemente
(parti) decat necesar

sub-segmentarea :



descompunerea imaginii in mai putine elemente
(parti) decat necesar

C. VERTAN




Cine [si cum] defineste numarul necesar, corect, de parti ale imaginii ?

sub-segmentare ?
(soarele este in clasa “cer”)




3 tipuri de elemente :
cer, vegetatie, casa



supra-segmentare ?
(copac impartit in doua clase)

4 tipuri de elemente :
cer, vegetatie, lemn, zid

C. VERTAN



Segmentare pe regiuni:

segmentarea in suportul imaginii

etichetarea imaginilor binare

segmentarea in spatiul caracteristicilor


cresterea (si fuziunea) regiunilor

segmentarea pe histograma

algoritmi generali de clustering


C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR




Solutie imediata : cresterea regiunilor

Determinarea unor zone in care se verifica uniformitatea valorilor unei caracteristici.



front de
crestere oprit de
neuniformitate



punct de plecare : germene

directie de inaintare
front de crestere

C. VERTAN



Cresterea regiunilor

Etape de rezolvat :

alegerea germenilor (punctelor de start)

alegerea criteriului de uniformitate a regiunii

Germenii :

se aleg in regiuni uniforme (sa fie plasati in centrul regiunilor)

se repartizeaza uniform in suportul spatial al imaginii

valoarea pixelilor germene trebuie sa fie reprezentativa pentru

distributia valorilor pixelilor din imagine

este preferabila alegerea unui numar mare de germeni, chiar

cu riscul supra-segmentarii

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Exemplu



germene

regiune,
 $T_{unif}=10$


C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Verificarea germenilor redundanti

(germenii ce conduc la suprasegmentare)




germeni redundanti :
exista cel putin o cale uniforma
care ii uneste

germeni ne-redundanti :
nu exista nici o cale uniforma care
sa ii uneasca (deci se trece peste
frontiera)


Numarul de cai testate (“toate”) este redus din considerente de calcul.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Verificarea germenilor redundanti (germenii ce conduc la suprasegmentare)




Deși germenii sunt plasati in aceeași componentă, nu sunt declarati redundanti : caile verificate care îi unesc traversează frontierele-obiect.

Obiectul va fi impartit (artificial) in două componente.

Supra-segmentarea poate fi partial corectata prin “fuziunea regiunilor”

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Cresterea efectiva a regiunilor

In jurul germenului se agregă pixeli vecini structurii deja existente, dacă valoarea acestor pixeli este suficient de apropiată de valoarea germenului.

Cresterea trebuie imaginată ca fiind simultană pentru toți germenii aleși în imagine.

Cresterea se oprește când pixelii rămași ne-alocați unei regiuni nu mai satisfac criteriul de uniformitate;
relaxarea criteriului de uniformitate
construirea unei clase a pixelilor “a-tipici”.

C. VERTAN

LABORATORUL DE ANALIZĂ ȘI PRELUCRAREA IMAGINILOR



Corectia rezultatelor : fuziunea regiunilor


Se verifica daca regiunile vecine nu ar putea fi reunite.

Criteriile de similaritate se refera in general la frontiera :

procentul de pixeli slabi

procentul de pixeli tari

altele ...





Concluzie : Procesul este complicat si de durata, necesita reglarea multor parametri. Cresterea regiunilor ar fi buna pentru separarea unui numar mic de obiecte fixate, nu pentru segmentarea imaginii întregi.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Tipurile de obiecte pot fi separate in **spatiul caracteristicilor**, daca respectivele caracteristici sunt **discriminante** (de ex. culoarea).



C. VERTAN



Cea mai simpla caracteristica: **nivelul de gri**

Presupunem ca nivelul de gri este reprezentativ si suficient pentru caracterizarea tipurilor de obiecte din imagine.

Trebuie deci identificate “concentrarile” de nivele de gri, adica **modurile din histograma imaginii**. Fiecare mod bine identificat va corespunde unui tip de obiecte din imagine.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Histograma

Histograma = functie ce asociaza fiecarui nivel de gri posibil probabilitatea [sa] de aparitie in imagine.

$h(u)$ = numar pixeli de nivel de gri “ u ” / numar total pixeli

$$h(u) = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \delta(f(m,n) - u), \quad u = 0, 1, \dots, L-1$$


Histograma este o functie de densitate de probabilitate.

$$\sum_{u=0}^{L-1} h(u) = 1$$





Histograma descrie continutul “de culoare/ de gri” al imaginii.

C. VERTAN







LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Histograma




Histograma



C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Segmentarea pe histograma = Thresholding (praguire)

gasirea “pragurilor” de separare dintre modurile histogramei de nivele de gri a imaginii.

Fie T_k pragurile de segmentare pe histograma.


$$g(m,n) = E_k, \text{ daca } T_k \leq f(m,n) \leq T_{k+1}$$

E_k este eticheta ce se atribuie tipului de obiecte k

$$T_0 = 0, T_C = L, k = 0, 1, \dots, L-1$$

Caz particular : $C = 2$ (binarizarea)

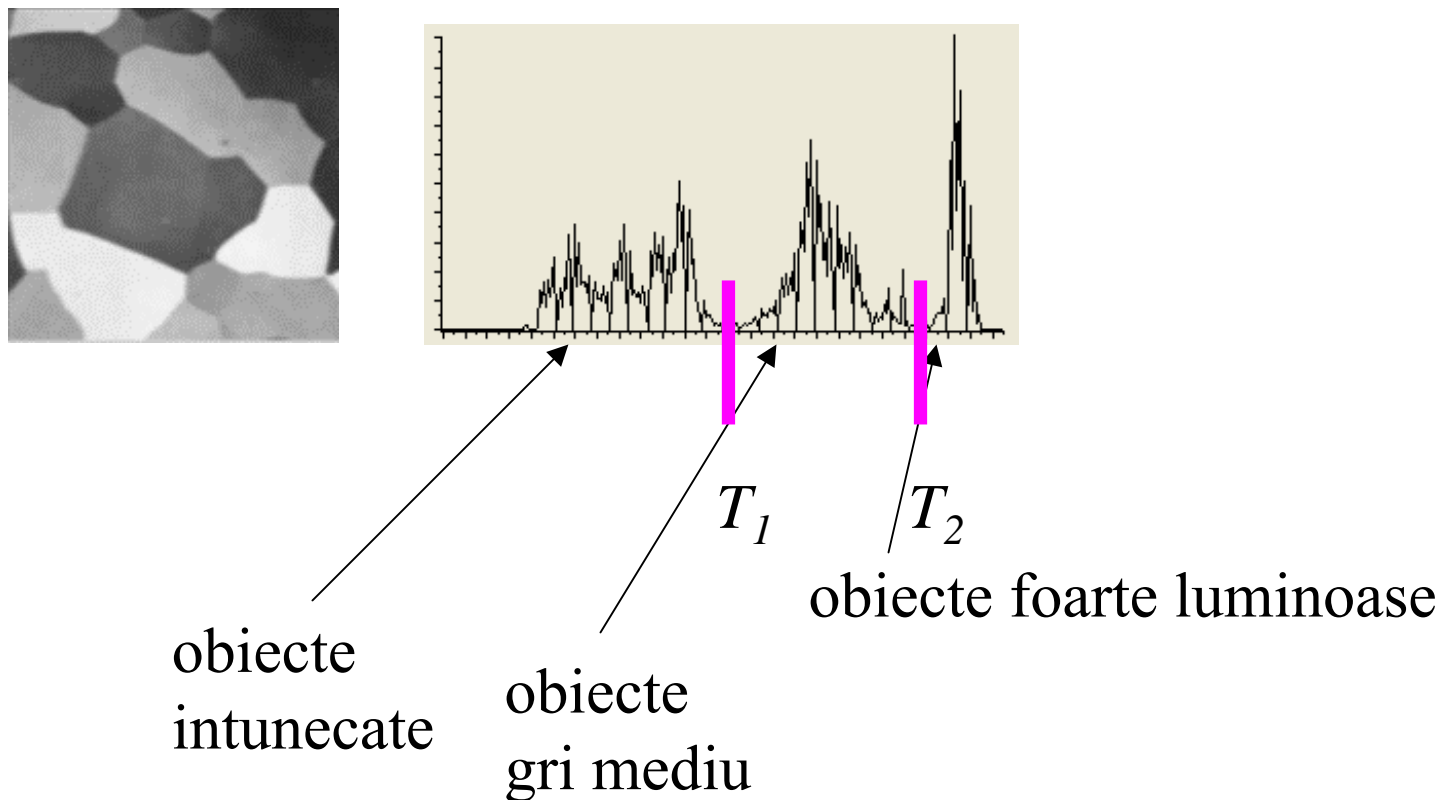
$$g(m,n) = \begin{cases} E_0, & f(m,n) \leq T \\ E_1, & f(m,n) > T \end{cases}$$



C. VERTAN




Evident, alegerea pragurilor de segmentare T_k este cruciala.




Pragurile se aleg pe minimele histogramei (separatia dintre moduri).

C. VERTAN


LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Exemplu



$C=2$
 $T=170$




C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR




Exemplu




$$\begin{aligned}C &= 3 \\ T_1 &= 40 \\ T_2 &= 100\end{aligned}$$



$$\begin{aligned}C &= 4 \\ T_1 &= 40 \\ T_2 &= 100 \\ T_3 &= \end{aligned}$$



C. VERTAN



Daca minimele histogramei nu sunt usor de identificat ?

Segmentare pe histograma ponderata

$$h'(u) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N w(m,n) \delta(f(m,n) - u), \forall u$$

$w(m,n)$ masura locala, caracteristica pixelului

$\Delta(i, j)$ Laplacianul imaginii


$$w(m,n) = \frac{1}{1 + |\Delta(m,n)|}$$

adancirea minimelor din histograma


$$w(m,n) = |\Delta(m,n)|$$

separatiile dintre moduri devin maxime

C. VERTAN




Exemplu




C. VERTAN




Exemplu




a)




c)



b)



d)



Segmentarea cu prag optim

Sa presupunem cunoscute: numarul de tipuri de obiecte din imagine, proportiile in care acestea ocupa suprafata imaginii si distributia nivelelor de gri caracteristice fiecarui tip de obiect.

$$h(x) = \sum_{i=1}^C P_i p_i(x)$$

$$\sum_{i=1}^C P_i = 1$$

Pentru binarizare $C=2$:

$$h(x) = P_1 p_1(x) + P_2 p_2(x)$$

$$P_1 + P_2 = 1$$

Pentru binarizare va trebui determinat pragul T ce separa modurile.


Pragul este “optim” in sensul minimizarii unei erori.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Eroarea de segmentare este data de pixelii prost etichetati:
nivel de gri mai mic ca T , desi provin din p_2
nivel de gri mai mare ca T , desi provin din p_1



$$\varepsilon(T) = P_2 \int_{-\infty}^T p_2(x) dx + P_1 \int_T^{+\infty} p_1(x) dx$$

C. VERTAN



Optim :

$$\frac{d\varepsilon(T)}{dT} = 0 \quad \Rightarrow \quad P_1 p_1(T) = P_2 p_2(T)$$
$$\varepsilon(T) = P_2 \int_{-\infty}^T p_2(x) dx + P_1 \int_T^{+\infty} p_1(x) dx$$

In cazul particular cel mai curent, distributiile ce caracterizeaza obiectele sunt normale (gaussiene).


Daca variantele lor sunt egale, pragul este:

$$T = \frac{\mu_1 + \mu_2}{2} - \frac{\sigma^2}{\mu_1 - \mu_2} \ln \frac{P_1}{P_2}$$


C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR






a)




b)



b)

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Segmentare globala

Metoda Bhattacharyya

Ipoteza: clasele de obiecte pot fi modelate cu distributii gaussiene.

Metoda: descompunerea histogramei imaginii in moduri normale.

Obs. ca :

$$N(\mu, \sigma)(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

$$\ln N(\mu, \sigma)(x) = -\ln \sqrt{2\pi\sigma^2} - \frac{(x-\mu)^2}{2\sigma^2}$$


$$\frac{d}{dx} \ln N(\mu, \sigma)(x) = -\frac{x}{\sigma^2} + \frac{\mu}{\sigma^2} = mx + n$$

C. VERTAN




Unui mod gaussian ii corespunde o dreapta descrescatoare in domeniul functiei discriminant (derivata logaritmului densitatii de probabilitate).

histograma
trimodala




functia discriminant
(derivata logaritmului
histogramei)



C. VERTAN





C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR




In functia discriminant se vor identifica deci domeniile pe care functia este descrescatoare. Aceste domenii separa modurile normale in histograma.


Parametrii modurilor sunt obtinuti din parametrii drepte de aproximare a functiei discriminant.

$$z(x) = \frac{d}{dx} \ln N(\mu, \sigma)(x) = -\frac{x}{\sigma^2} + \frac{\mu}{\sigma^2} = mx + n$$

Segmentarea se va face dupa praguri alese pe capetele intervalelor de descrestere a functiei discriminant.




Alternativ: nivelele de gri din interiorul fiecarui mod sunt inlocuite cu media modului respectiv.



Segmentarea poate fi vazuta astfel ca o problema de aproximare a valorilor imaginii.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR





Original:
230 nivele gri



Aproximare 1:
22 nivele gri
SNR= 29.6 dB



Aproximare 2:
13 nivele gri
SNR=20.4 dB

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR





Original:
247 nivele gri



Aproximare 1:
40 nivele gri
SNR= 35 dB



Aproximare 2:
13 nivele gri
SNR=24 dB

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Observatii:

Numarul de moduri nu poate fi controlat decat prin impunerea unei lungimi minime a unui interval de descrestere a functiei discriminant si a unei erori mici de aproximare cu o dreapta.

Putem considera ca metoda imi asigura o legatura intre conceptele de segmentare si cuantizare (aproximare a valorilor initiale cu alte valori, in numar mai mic).

Apar probleme daca ipoteza de normalitate a modurilor nu este adevarata.

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Segmentare globala

Metode bazate pe histograma cumulativa

$$H(j) = \sum_{i=1}^j h(i), \quad j = 0, 1, \dots, L-1.$$

functia de rapartitie asociata
histogramei

Presupunand ca obiectele de interes sunt de nivel de gri inchis si ocupa o arie relativa $P\%$ din imagine, atunci pragul de segmentare T se determina prin:


$$H(T) \cong P.$$


Pentru obiecte de interes luminoase,

$$H(T) \cong 1 - P$$

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR





C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Dar daca nivelul de gri nu este suficient ?
(si la histograma ponderata se foloseau caracteristici suplimentare)


Dar daca imaginile nu sunt scalare ?
(imaginile color au 3 numere/ pixel)

Segmentarea generala in spatiul caracteristicilor prin clustering.


C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR






a)




b)



c)

Figura 4.14: Construirea unui spațiu al caracteristicilor multi-dimensional: a) imagine originală; b) imagine obținută ca urmare a unei filtrări de mediere locală; c) reprezentarea pixelilor din imagine în spațiul caracteristicilor (nivel de gri, nivel de gri mediu) – se observă că în acest spațiu bidimensional al caracteristicilor apare o evidentă separare a două grupuri de pixeli, ce corespund obiectului de interes și respectiv fundalului; d) rezultatul binarizării imaginii originale




Segmentarea inseamna identificarea grupurilor de pixeli ce au caracteristici asemanatoare.

Acest proces de grupare se numeste *clustering* (denumirea generala).


Algoritmi de clustering urmaresc identificarea automata a unor grupuri de puncte din spatiul caracteristicilor ce sunt :

compacte, dense
reprezentative
bine separate



C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Punerea problemei :

un set de N puncte, descrise de vectori de dimensiune p
trebuie impartit in C clase (grupuri, clustere).

$$X = \{ \mathbf{x}_i \}, i = 1, 2, \dots, N$$

$$\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{ip})$$

Impartirea (partitionarea) setului de puncte in clase :

indice de apartenenta a fiecarui punct (carei clase ii apartine)

Exprimarea cantitativa a conceptului de “partitionare buna”.
criterii de calitate a partitiei.



Apartenența punctelor la clase

Apartenența punctului \mathbf{x}_i la clasa j :

$$u_{ij}, \quad i = 1, 2, \dots, N, \quad j = 1, 2, \dots, C$$

Modele de clustering :

Net (binar) :

Nuantat (fuzzy) :

$$u_{ij} = \begin{cases} 1, \mathbf{x}_i \in Clasa_j \\ 0, \mathbf{x}_i \notin Clasa_j \end{cases}$$

$$u_{ij} \in [0, 1] \\ \forall \quad i = 1, 2, \dots, N, \quad j = 1, 2, \dots, C$$



Masuri de calitate a claselor

clase compacte : centrul clasei este “aproape” de toate punctele clasei (punctele clasei sunt bine approximate de centrul clasei).

clasa are suficient de multe puncte

clase bine separate : distantele dintre centrele claselor sa fie cat mai mari.

Cele doua cerinte sunt adeseori contradictorii.



Basic ISODATA (k-means, C-means)

ISODATA = **I**terative **S**elf **O**rganizing **D**ata **A**nalysis **T**echnique

Se fixeaza numarul de clase dorit, C .

Calitatea partitiei (a claselor) e caracterizata de eroarea globala de aproximare a vectorilor de date prin prototipurile claselor.

$$J = J(u_{ij}, \mu_j) = \sum_{j=1}^C \varepsilon_j = \sum_{j=1}^C \left(\sum_{i=1}^N u_{ij} \|\mathbf{x}_i - \mu_j\|^2 \right)$$

μ_j prototipul (centroidul) clasei j



Basic ISODATA (C-means)


$$\frac{\partial J}{\partial \boldsymbol{\mu}_j} = 2 \sum_{i=1}^N u_{ij} (\mathbf{x}_i - \boldsymbol{\mu}_j) = 0$$

$$\boldsymbol{\mu}_j = \frac{\sum_{i=1}^N u_{ij} \mathbf{x}_i}{\sum_{i=1}^N u_{ij}}$$

prototipurile claselor sunt mediile aritmetice ale vectorilor de date ce apartin claselor.

$$u_{ij} = \begin{cases} 1, & \|\mathbf{x}_i - \boldsymbol{\mu}_j\| \leq \|\mathbf{x}_i - \boldsymbol{\mu}_k\|, \forall k \neq j \\ 0, & \text{rest} \end{cases}$$

orice vector apartine clasei de al carei prototip este cel mai apropiat.




Basic ISODATA (C-means)

1. alege un set aleator de prototipuri
2. calculeaza apartenenta fiecarui vector la una dintre clasele partitiei (vectorii apartin clasei de al carei prototip sunt cei mai apropiati)
3. calculeaza prototipurile claselor ca media aritmetica a vectorilor apartind fiecarei clase
4. evalueaza criteriu de oprire :
 - eroare globala suficient de mica ?
 - numar de iteratii suficient de mare ?
 - au fost vectori care sa isi schimbe apartenenta ?
 - au fost prototipuri care s-au modificat semnificativ ?
5. repeta de la 2 daca e cazul.

Problema :

“oscilatii” ale vectorilor intre clase

alocarea vectorilor situati la egala distanta fata de clase



C. VERTAN



Clustering fuzzy

Orice vector apartine oricarei clase, dar intr-o masura mai mare sau mai mica.

u_{ij} sunt gradele de apartenenta [fuzzy] ale vectorilor la clase.

Probleme

de ce fuzzy ?

ce semnificatie au gradele de apartenenta ?

cum se modifica criteriile obiective de calitate ?

C. VERTAN


LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Fuzzy : cum ?

Numerele corespund masurii in care un obiect din universul problemei satisface o proprietate (sau o categorie) semantica; numerele sunt in $[0,1]$.


Multime fuzzy = functie de apartenenta a obiectelor la categoria data



Functia de apartenenta corespunde unui model natural (plauzibil) si nu este « machiavelica » (Bezdeck)



Un model «machiavelic» al categoriei «Inalt»:



Gradele de apartenenta nu sunt acelasi lucru cu probabilitatile !

Exemplul calatorului insetat (Bezdeck) :

Calatorul insetat ce merge prin desert gaseste doua sticle pline cu lichid. Calatorul trebuie neaparat sa bea continutul unei sticle. Etichetele sticlelor nu sunt “clare”.



Fuzzy \neq probabilitate



Probabilitatea unui continut «potabil » : 0.9



Gradul de apartenenta al continutului la
categoria «potabil» : 0.9

Probabilitatea : o sansa din zece de a gasi in sticla acid.

Gradul de apartenenta : continutul este foarte potabil
(ar putea fi bere).

Gradul de apartenenta nu se schimba dupa observatie !

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Fuzzy \neq probabilitate



Probabilitatea unui continut «potabil » : 0.1



Gradul de apartenenta al continutului la
categoria «potabil» : 0.1


Probabilitatea : noua sanse din zece de a gasi in sticla acid.

Gradul de apartenenta : continutul este foarte putin potabil
(aproape sigur este acid).

Gradul de apartenenta nu se schimba dupa observatie !

C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



Moduri de interpretare a gradelor de apartenenta

Clustering “probabilist” - gradele de apartenenta reprezinta masura in care vectorii sunt “impartiti” claselor

$$\sum_{j=1}^C u_{ij} = 1 \quad (\text{constrangerea de normare probabilista})$$

Clustering “posibilist” - gradele de apartenenta reprezinta masura in care vectorii sunt “tipici” pentru clase
(fara constrangeri de normare)



FCM - Fuzzy C-Means (Fuzzy Isodata)

“probabilist”

Se fixeaza numarul de clase dorit, C .

Calitatea partitiei (a claselor) e caracterizata de eroarea globala de aproximare a vectorilor de date prin prototipurile claselor.

$$J = J(u_{ij}, \mu_j) = \sum_{j=1}^C \mathcal{E}_j = \sum_{j=1}^C \left(\sum_{i=1}^N u_{ij}^m \left\| \mathbf{x}_i - \mu_j \right\|^2 \right)$$

μ_j prototipul (centroidul) clasei j
 m gradul de fuzificare al partitiei

$$J_{FCM} = \sum_{j=1}^C \left(\sum_{i=1}^N u_{ij}^m \left\| \mathbf{x}_i - \mu_j \right\|^2 \right) - \sum_{i=1}^N \lambda_i \left(\sum_{j=1}^C u_{ij} - 1 \right)$$

C. VERTAN



Clustering fuzzy “probabilist”

$$\frac{\partial J_{FCM}}{\partial \mathbf{\mu}_j} = 2 \sum_{i=1}^N u_{ij}^m (\mathbf{x}_i - \mathbf{\mu}_j) = 0$$

$$\mathbf{\mu}_j = \frac{\sum_{i=1}^N u_{ij}^m \mathbf{x}_i}{\sum_{i=1}^N u_{ij}^m}$$

prototipul oricarei clase este o medie ponderata a tuturor vectorilor din setul de date, ponderati cu gradele lor de apartenenta la clasa respectiva.

$$\frac{\partial J_{FCM}}{\partial u_{ij}} = m u_{ij}^{m-1} \|\mathbf{x}_i - \mathbf{\mu}_j\|^2 - \lambda_i = 0 \Rightarrow u_{ij} = \left(\frac{\lambda_i}{m \|\mathbf{x}_i - \mathbf{\mu}_j\|^2} \right)^{\frac{1}{m-1}}$$

$$\sum_{k=1}^C u_{ik} = 1 \Rightarrow \lambda_i = \left(\frac{m}{\sum_{k=1}^C \|\mathbf{x}_i - \mathbf{\mu}_k\|^{-\frac{2}{m-1}}} \right)^{m-1}$$

C. VERTAN



Clustering fuzzy “probabilist”

$$u_{ij} = \frac{\left\| \mathbf{x}_i - \boldsymbol{\mu}_j \right\|^{-\frac{2}{m-1}}}{\sum_{k=1}^C \left\| \mathbf{x}_i - \boldsymbol{\mu}_k \right\|^{-\frac{2}{m-1}}}$$


$$u_{ij} = \frac{\frac{1}{\text{dist}^{\frac{2}{m-1}}(\mathbf{x}_i, \boldsymbol{\mu}_j)}}{\sum_{k=1}^C \frac{1}{\text{dist}^{\frac{2}{m-1}}(\mathbf{x}_i, \boldsymbol{\mu}_k)}}$$

gradele de apartenenta depind
invers proportional de patratele
distantelor de la vectorul de date
la prototipurile claselor

rezolva problema gradelor de apartenenta egale in cazul vectorilor
egal distantati de prototipuri ale claselor.

C. VERTAN


LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR



FCM (Fuzzy Isodata)

1. alege un set aleator de prototipuri
2. calculeaza apartenenta fiecarui vector la clasele partitiei
3. calculeaza prototipurile claselor ca mediile ponderate ale vectorilor
4. evalueaza criteriu de oprire :
 - eroare globala suficient de mica ?
 - numar de iteratii suficient de mare ?
 - au fost vectori care sa isi schimbe apartenenta ?
 - au fost prototipuri care s-au modificat semnificativ ?
5. repeta de la 2 daca e cazul.

C. VERTAN



Exemplu

Clustering fuzzy “probabilist”



FCM, $C=3$



segmentare ideala ($C=3$)
C. VERTAN




FCM, $C=4$



Clustering fuzzy “probabilist”

Limitările modelului de “impartire” a vectorului
intre clase.



C. VERTAN



C. VERTAN

LABORATORUL DE ANALIZA ȘI PRELUCRAREA IMAGINILOR

