





Procesarea Imaginilor si Viziune Artificiala

Curs 3

Conf. dr. ing. Remus BRAD, Universitatea “Lucian Blaga” din Sibiu



Elemente de procesare de nivel inalt

Segmentarea (cont.)

Transformata Ahuja pentru segmentarea imaginilor

Considerații legate de segmentarea imaginilor

Transformata


$$\mathbf{F}(x, y; \sigma_g(x, y), \sigma_s(x, y)) = \iint_R d_g(\Delta I, \sigma_g(x, y)) \cdot d_s(\vec{r}, \sigma_s(x, y)) \frac{\vec{r}}{\|\vec{r}\|} dw dv$$

unde $R = \text{domeniul}(I(u, v)) \setminus \{(x, y)\}$, $\vec{r} = (v-x)\vec{i} + (w-y)\vec{j}$ $\Delta I = |I(x, y) - I(v, w)|$


$$\begin{aligned} d_g(\Delta I, \sigma_g) &\approx B_{\Delta I}(\sigma_g) \\ d_s(\vec{r}, \sigma_s) &\approx B_{\|\vec{r}\|}(\sigma_s) \end{aligned} \quad B_x(c) = \begin{cases} 1 & |x| \leq c \\ 0 & \text{altfel} \end{cases}$$

$$\mathbf{F}(x, y; \sigma_g(x, y), \sigma_s(x, y)) = \mathbf{F}_{\sigma_g}(x, y)$$

Transformata Ahuja pentru segmentarea imaginilor




a)




b)

- a) Pentru un $\sigma_g < 10$, cercul $C1$ conține destulă informație pentru a identifica un contur în punctul P . Pentru o valoare mai mare a lui σ_g , decizia va fi posibilă folosind vecinătatea cercului $C2$. b) vecinătatea $C3$ conține prea multă informație pentru a decide asupra existenței conturului în punctul P .

Transformata Ahuja pentru segmentarea imaginilor



a)



b)

a) Alegerea potrivită a lui σ_s duce la transformarea regiunii într-o zonă de atracție constând dintr-o singură regiune cu flux convergent. b) σ_s a fost ales prea mare și zona de atracție conține mai multe regiuni de flux convergent.

Transformata Ahuja pentru segmentarea imaginilor

Determinarea valorilor lui σ_s

Se definește limita de jos a intervalului:

$$\sigma_s^- = \min(\sigma_s) \text{ astfel încât } \|\mathbf{F}_{\sigma_g}(x_0, y_0)\| \geq T(\sigma_g, \sigma_s)$$


$$T = 4$$

marginea superioară a intervalului:


$$\sigma_s^+ = \min(\sigma_s) \text{ astfel încât } \frac{d}{d\sigma_s} \left| \frac{d}{d\sigma_s} \theta(\sigma_s) \right| \geq 0$$

pentru $\sigma_s \geq \sigma_s^-$. Alegând $\sigma_s(x_0, y_0) \in [\sigma_s^-, \sigma_s^+]$ pentru fiecare pixel, obținem un câmp $\mathbf{F}$ având fiecare vector de forță aparținând unei regiuni de atracție

Transformata Ahuja pentru segmentarea imaginilor



a)




b)

a) O imagine conținând pătrate de culoare neagră. b) Graficul variației direcției forței corespunzător lui σ_s , pentru pixelul ce aparține pătratului A.

Transformata Ahuja pentru segmentarea imaginilor

Identificarea regiunilor de atracție din F



a) b) c)

a) Imaginea originală; b) unghiurile forțelor reprezentate în nuanțe de gri pentru $\sigma_g=30$; c) reprezentarea vectorială a câmpului de forțe F .

Transformata Ahuja pentru segmentarea imaginilor


daca $\mathbf{F}_{\sigma_{g_0}}(x_0, y_0) \leq 0$ si $\mathbf{F}_{\sigma_{g_0}}(x_0 + 1, y_0) \geq 0$

$$\text{si } \frac{\mathbf{F}_{\sigma_{g_0}}(x_0, y_0) \cdot \mathbf{F}_{\sigma_{g_0}}(x_0 + 1, y_0)}{\|\mathbf{F}_{\sigma_{g_0}}(x_0, y_0)\| \|\mathbf{F}_{\sigma_{g_0}}(x_0 + 1, y_0)\|} < \cos \varepsilon$$


atunci (x_0, y_0) și (x_0+1, y_0) sunt puncte de frontieră

Transformata Ahuja pentru segmentarea imaginilor



influența factorului de omogenitate asupra segmentării




a) Imaginea originală







b) unghiurile forțelor și contururile determinate pentru $\sigma_g=30$



c) unghiurile forțelor și contururile determinate pentru $\sigma_g=60$



Transformata Ahuja pentru segmentarea imaginilor



Segmentarea imaginilor satelit

// 1. preprocesarea imaginii în scopul netezirii

netezire cu un filtru gaussian având $\sigma = 2$

// 2. aplicarea transformatei

pentru o valoare prestabilită a omogenității σ_g

pentru fiecare pixel din imagine

 pentru valori crescânde ale vecinătății σ_s

 se determină valoarea forței

 se calculează unghiul forței pentru intervalul de stabilitate

// 3. determinarea apartenenței pixelilor la contur sau linii mediane

pentru fiecare pixel din imagine

 se compară cu vecinii săi

 divergență a forțelor => pixel de contur

 convergență a forțelor => pixel al liniei mediane

// 4. determinarea regiunilor omogene prin "region growing"

pentru fiecare din pixelii aflați pe linii mediane din imagine

 se "crește" regiunea, marcând toți pixelii vecini

 se oprește "creșterea" atunci când


 se întâlnesc pixeli aparținând conturului sau

 se depășește factorul de omogenitate σ_g


Rezultate




a) după etapa 1



b) după etapa 2




c) după etapa 3



d) după etapa 4

Rezultate


secvență de **imagini METEOSAT** infraroșu



a)




b)




c)


secvență de **imagini segmentate** (σ_g ales în concordanță cu specificația EUMETSAT)




d)



e)



f)



Elemente de procesare de nivel inalt

Recunoasterea de forme


Transformata Hough

- Ecuatia dreptei ce trece prin punctul de coordonate (x_i, y_i) :

$$y_i = ax_i + b$$


- Dar daca rescriem: $b = -x_i a + y_i$ **à**
ecuatia unei drepte in spatiul a b

Transformata Hough



Transformata Hough

- O dreapta in spatiul (x,y) ce trece prin mai multe puncte, va avea o valoare precisa a parametrilor (a,b)
- O dreapta in spatiul parametric (a,b) semnifica toate dreptele ce trec printr-un anumit punct (x_i, y_i) (pot fi o infinitate)







Transformata Hough

In concluzie:

- O dreapta se reprezinta printr-un punct in spatiul (a,b)
- Doua drepte in spatiul (a,b) parametric ce se intersecteaza intr-un punct, denota ca exista puncte ce apartin aceleiasi drepte in spatiul (x,y)

Transformata Hough


Se creaza un accumulator



Transformata Hough


- Deoarece a, b devin infinit atunci cind dreapta devine verticala, se foloseste de obicei reprezentarea:

$$d = x \cos \theta + y \sin \theta$$




Transformata Hough

- 1 punct $\Rightarrow$ o sinusoida









- 2 puncte $\Rightarrow$ 2 sinusoide

Punctul de intersectie a lor
reprezinta dreapta ce trece prin
cele doua puncte




Transformata Hough

Efectul zgomotului
asupra detectiei



Transformata Hough

Exemplu




Transformata Hough


- Transformata se poate aplica oricarei functii de forma $g(v,c) = 0$ unde v este vectorul coordonatelor iar c reprezinta coefficientii
- Spre exemplu, punctele de pe un cerc:

$$(x_i - a)^2 + (y_i - b)^2 = r^2$$



Transformata Hough



Spatiu coordonatelor






Spatiu parametric





Transformata Hough

Exemplu



Transformata Hough



Transformata Hough

Linii:


- <http://www.dis.uniroma1.it/~iocchi/slides/icra2001/java/hough.html>

Cercuri:

- <http://www.markschulze.net/java/hough/>

Urmărirea contururilor

- Poate fi aplicata imaginilor ce contin informatii legate de contur (spre exemplu detectie de contur/binarizare)
- Dupa ce a fost detectat un punct de contur, operatorul cauta toti ceilalti pixeli ce apartin conturului
- Metoda consta in:



- Se gaseste pixelului initial de contur (1);
- Se cauta cei 8 vecini pentru a se gasi urmatorul pixel de contur (2);
- Se cauta in aceeaasi directie (se admite o deviatie de 1 pixel);
- Se repeta pasul 3 pina cind nu se mai gasesc alte puncte de contur.

Algoritmul de urmarire al unui contur

Se verifica pixelii vecini ai punctului de start, astfel:

- Se aleg 3 pixeli cu valoarea cea mai mare a gradientului
- Se sorteaza cei 3 pixeli in ordine descrescatoare, iar tripleta de pixeli va fi stocata intr-o lista
- Se alege pixelul cu valoarea cea mai mare a gradientului
- Setam directia de deplasare conform conventiei
- Se inainteaza cu un pas in directia aleasa (dir)
- Se seteaza pixelul curent ca vizitat
- Se verifica cei trei pixeli vecini din directiile: $dir - 1$, dir , $dir + 1$
- Se sorteaza pixelii descrescator si se stocheaza intr-o lista ca un triplet
- Se alege primul pixel (cu gradientul cel mai mare)

Algoritmul de urmarire al unui contur

Se repeta pana cand se gaseste un pixel candidat valid

- IF pixelul candidat este nevizitat si gradientul este $>$ threshold, THEN pixelul este parte a conturului si se scoate pixelul din lista
ELSE
- IF mai sunt pixeli candidati in triplet THEN
Se trece la urmatorul pixel din triplet
ELSE se sterge tripletul gol si se trece cu o pozitie inapoi in lista
- Se face un pas inainte in directia respectiva

0	1	2
7	*	3
6	5	4

Exemplu

Imagine Originala										
	1	2	3	4	5	6	7	8	9	10
1	8	9	10	11	12	13	14	15	16	17
2	9	10	11	12	13	14	15	16	17	18
3	10	11	12	13	14	15	16	17	18	19
4	11	12	13	24	25	26	27	18	19	20
5	12	13	14	25	26	27	28	19	20	21
6	13	14	15	26	27	28	19	20	21	22
7	14	15	16	27	28	19	20	21	22	23
8	15	16	17	18	19	20	21	22	23	24
9	16	17	18	19	20	21	22	23	24	25
10	17	18	19	20	21	22	23	24	25	26

Sa alege punctul cu coordonatele $[4, 4] = 76$ ca punct de start. Setam pragul de gradient la 20. Pentru primul punct alegem primii 3 pixeli cu gradientul cel mai mare: $[4, 3]$, $[5, 3]$ si $[3, 4]$ in aceasi ordine.

Se trece la pixelul $[4, 3]$, urmasorii pixeli: $[3, 2]$, $[4, 2]$ si $[5, 2]$ nu respecta testul pragului, deci punctul $[4, 3]$ este sters.

Urmatorul pixel este $[5, 3]$ si produce tripelul: $[6, 3]$, $[5, 2]$ si $[6, 2]$ din care se alege primul, etc.

0	1	2
7	*	3
6	5	4

Gradienti Sobel										
	1	2	3	4	5	6	7	8	9	10
1	-	-	-	-	-	-	-	-	-	-
2	-	16	16	16	16	16	16	16	16	-
3	-	16	36	56	56	56	40	20	16	-
4	-	16	56	76	56	56	60	40	16	-
5	-	16	56	56	16	4	44	24	16	-
6	-	16	56	56	4	44	44	4	16	-
7	-	16	40	60	44	44	4	16	16	-
8	-	16	20	40	24	4	16	16	16	-
9	-	16	16	16	16	16	16	16	16	-
10	-	-	-	-	-	-	-	-	-	-

Step	1 st candidate	2 nd candidate	3 rd candidate
1	(4,3)=56	(5,3)=56	(3,4)=56
2	(3,2)=16	(4,2)=16	(5,2)=16
3	(6,3)=56	(5,2)=16	(6,2)=16
4	(7,4)=60	(7,3)=40	(7,2)=16
5	(7,5)=44	(8,4)=40	(8,5)=24
6	(6,6)=44	(7,6)=44	(8,6)=4
7	(5,7)=44	(6,7)=44	(5,6)=4
8	(4,7)=60	(4,8)=40	(5,8)=24
9	(3,6)=56	(3,7)=40	(3,8)=20
10	(3,5)=56	(2,5)=16	(2,6)=16
11	(4,4)=76	(3,4)=56	(2,4)=16

Reprezentarea contururilor

- Trebuie stabilita anumite reguli pentru determinarea carui obiect ii apartine un pixel
- Sint utilizate doua scheme:
 - conectivitate cu 4 vecini
 - un pixel este considerat avind 4 vecini
 - conectivitate cu 8 vecini
 - un pixel este considerat avind cei mai apropiati 8 vecini

	1	
2	X	0
	3	

Pixeli cu 4 vecini


3	2	1
4	X	0
5	6	7

Pixeli cu 8 vecini

Reprezentarea contururilor

- Utilizarea unui format compact pentru stocarea informatiilor referitoare la un obiect
- Se poate coda directia contururilor unui obiect
- Foloseste proprietatea de vecinatate a pixelilor de contur (vecinatate de 4 sau de 8)
- Reprezentare pe 3 biti pentru fiecare punct
- Se alege un punct se start arbitrar pe contur
- Se cauta pixelul vecin de pe contur folosind o regula (sensul acelor de ceasornic)
- Se memoreaza directiile contururilor ca si o lista de coduri

3	2	1
4	n	0
5	6	7




Start point (204, 463)

Boundary Chain code:

204 463

5660702122435



Detecția mișcării din secvențe de imagini

Iluzii optice

- Bazate pe miscare

http://www.sandlotscience.com/Guided_Tours/Tour2/Tour_2_Main.htm

Introducere

Există trei grupe principale de probleme legate de mișcare:

1. **Deteția mișcării**
2. **Detectia mișcării obiectelor și localizarea lor**
3. **Reconstituirii caracteristicilor obiectelor 3D**

Analiza mișcării

Fazele analizei mișcării

1. Faza detecției mișcării: Acest proces are drept scop extragerea dintr-o secvență de imagini a suprafețelor aflate în mișcare și a suprafețelor imobile, printr-o serie de observații bazate pe diferențele între cadre. Rezultatul acestui proces este o informație binară a prezenței sau a absenței mișcării și o mapare spațială a conturilor obiectelor mobile. Un set de două imagini poate fi insuficient pentru a reduce ambiguitățile de detecție cum ar fi suprapunerile de obiecte, acoperirile, modificarea suprafeței obiectului în mișcare.


2. Faza estimării mișcării: Scopul acestei etape este de a cuantiza informația percepută relativ la mișcare (viteza aparentă), pe baza observării imaginilor. Studiul acestei faze a produs un număr mare de algoritmi, în sensul determinării câmpului vectorilor de mișcare. Câmpurile astfel obținute sunt caracterizate prin:

- densitatea lor: câmpul dens, dacă măsura a fost aplicată fiecărui pixel, sau câmpul dispers, dacă faza de estimare este făcută la nivelul trasăturilor din imagini.
- tipul de primitive implicat: mișcări locale bazate pe pixel (cazul 1-D), mișcări ale conturilor, mișcări ale regiunilor (cazul 2-D), mișcări de obiecte (cazul 3-D).

3. Faza segmentării bazate pe mișcare: La fel ca și în faza detecției, se poate analiza o scenă prin intermediul regiunilor omogene, ca un criteriu de mișcare. Spre deosebire de detecția mișcării, un algoritm de segmentare bazat pe mișcare realizează împărțirea imaginii în regiuni având mișcări distincte și identificabile.

4. Faza interpretării mișcării: Pentru multe aplicații de analiză a scenei, cât și pentru cele de codare semantică cu modele de mișcare prestabilite, este de interes analiza unei secvențe de imagini numai prin intermediul definiției calitative a mișcării: obiectul 1 - rotație, obiectul 2 - scalare etc.. Aceste interpretări de nivel înalt se obțin din faze anterioare, de nivel scăzut, ale detecției sau segmentării. Acest tip de procesare este esențial atunci când, într-un sistem de comunicație, este necesară realizarea unei compresii și diagnoze cu aceeași procesare algoritmică. Acesta este cazul sistemelor de monitorizare activă ce utilizează rețelele de comunicație video.

5. Faza compensării mișcării: Această fază de procesare este specifică etapei de compresie a datelor. Compensarea mișcării unei imagini implică o analiză a priori a mișcării și exploatarea datelor astfel obținute pentru a crea o imagine virtuală $I_{comp}(x,y;t)$.




Fazele analizei mișcării

Elemente ale analizei mișcării

Reprezentarea în două dimensiuni a unei mișcări în trei dimensiuni se numește **câmp de mișcare**. Fiecărui punct din cadrul acestui câmp îi este asociat un **vector de viteză** în concordanță cu direcția mișcării, a vitezei și a distanței față de observator.


O abordare diferită analizează mișcarea prin calculul **fluxului optic**. În acest caz este necesară o diferență de timp foarte mică între două imagini consecutive, fără să existe schimbări importante de la o imagine la alta. Calculul fluxului optic rezultă din determinarea direcției mișcării și a vitezei de deplasare a tuturor punctelor imaginii.



Exemple de fluxuri optice

Dacă analiza mișcării se bazează pe detecția obiectelor în mișcare, atunci următoarele ipoteze pot ușura etapa de localizare a obiectelor:

- **Viteza maximă.** Să presupunem că sunt preluate imagini ale unui obiect în mișcare la intervale de timp dt . Poziția unui punct ce face parte din obiect, în imaginile viitoare, va fi în interiorul unui cerc ce are centrul în poziția inițială a punctului din obiect și de rază $c_{max}dt$, unde c_{max} este viteza maximă de mișcare a obiectului.
- **Accelerații mici.** Modificarea în timp a vitezei este limitată la valoarea unei constante.
- **Similaritate în mișcare.** Toate punctele obiectului se mișcă în mod similar.
- **Corespondența.** Obiectele rigide au aceeași conformație în timp. Fiecare punct al unui obiect corespunde exact unui punct din următoarea imagine și vice versa. Există și excepții datorate rotațiilor sau ocluziilor.



Ipoteze asupra mișcării obiectelor: a) viteza maximă;
b) accelerație mică; c) obiecte rigide


Barber pole illusion



Barber's pole



Motion field



Optical flow

Metode de analiză a mișcării

Metoda diferențială


Simpla “scădere” a imaginilor, surprinse la un anumit interval de timp poate să facă posibilă detecția mișcării, presupunând o cameră video fixă și o iluminare constantă. Diferența dintre imaginile consecutive $I(i,j,t-1)$ și $I(i,j,t)$, $d(i,j)$, este o imagine binară, în care valorile diferite de zero aparțin zonelor aflate în mișcare, adică zone în care există o diferență semnificativă între nivelele de gri.

$$d(i,j) = \begin{cases} 0 & \text{daca } |I(i,j,t) - I(i,j,t-1)| \leq \varepsilon \\ 1 & \text{altfel} \end{cases} \quad (2.2)$$


unde ε este un număr pozitiv mic.

Fie $I(i,j,t-1)$ și $I(i,j,t)$ două imagini consecutive preluate la un interval de timp. Un element $d(i,j)$ al imaginii diferență dintre $I(i,j,t-1)$ și $I(i,j,t)$ poate avea valoarea 1 în oricare din cazurile următoare:

- a) $I(i,j,t)$ este un pixel ce aparține unui obiect aflat în mișcare
 $I(i,j,t-1)$ este un pixel ce aparține fundalului static (sau invers)
- b) $I(i,j,t-1)$ este un pixel ce aparține unui obiect aflat în mișcare
 $I(i,j,t)$ este un pixel ce aparține altui obiect aflat și el în mișcare
- c) $I(i,j,t-1)$ este un pixel ce aparține unui obiect aflat în mișcare
 $I(i,j,t)$ este un pixel ce aparține altei părți a aceluiași obiect în mișcare
- d) zgomot, imprecizia în poziționarea camerei video statice.



Metoda diferențială de detecție a mișcării: a) și b) secvența de imagini ale satelitului NOAA GOES 8; c) imaginea diferența



Erori de detecție a mișcării; a) poziția obiectului la momentele de timp t_1 (gri) și t_2 ; b) câmpul de mișcare rezultat

Fluxul optic

Fluxul optic reflectă modificările din imagini datorate mișcării dintr-un intervalul de timp dt . Câmpul de flux optic este câmpul de viteze ce reprezintă mișcarea tridimensională a punctelor obiectului transpusă într-o imagine bidimensională. Fluxul optic este o abstracție ce ar trebui să reprezinte numai acele modificări de intensitate din imagine datorate mișcării, iar toate celelalte schimbări din imagini reflectate în fluxul optic să fie considerate erori ale detecției fluxului optic. De exemplu fluxul optic nu ar trebui să fie sensibil la schimbări ale iluminării sau la mișcări ale umbrelor. Totuși, un flux optic diferit de zero este detectat în cazul unei sfere statice iluminate de o sursă în mișcare. În mod asemănător, o sferă de suprafață netedă în rotație, iluminată de o sursă statică produce un flux optic nul, în ciuda unui câmp de viteze diferit de zero.

Calculul fluxului optic se bazează pe două premize:

1. strălucirea fiecărui punct al obiectului este constantă în timp;
2. puncte vecine din planul imaginii au mișcări similare.

Fluxul optic poate oferi o descriere a mișcării și contribuie la buna interpretare a imaginii, chiar dacă nu se obțin parametri cantitativi din analiza mișcării. Fluxul optic se folosește pentru a studia o varietate largă de mișcări:

- observator ce se mișcă și obiecte statice;
- observator static și obiecte ce se mișcă;
- observator și obiecte aflate în mișcare.


Mișcarea, așa cum apare în imaginile dinamice, este în general o combinație de patru elemente de bază:

1. translație la o distanță constantă de observator;
2. translație în adâncime relativ la observator;
3. rotație la distanță constantă pe axa de rotație;
4. rotație a unui obiect perpendicular pe axa vederii.


Analiza mișcării bazată pe fluxul optic poate recunoaște aceste elemente de bază, prin aplicarea unor operatori relativ simplii. Recunoașterea mișcării se bazează pe următoarele date, așa cum sunt ilustrate și în figura 2.6:

- translația la distanță constantă este reprezentată ca un set de vectori paraleli;
- translația în adâncime formează un set de vectori ce au un punct comun de expansiune;
- rotația la distanță constantă rezultă dintr-un set vectori de mișcare concentrici;
- rotația perpendiculară pe axa de vedere formează unul sau mai multe seturi de vectori pornind direct de la liniile de segment drepte.


Determinarea exactă a axei de rotație sau traiectoriei de translație poate fi realizată, dar cu o creștere considerabilă a efortului de analiză.




a)



b)




c)



d)




Formele de mișcare: a) translație la distanță constantă; b) translație în adâncime;
c) rotație la distanță constantă; d) rotație perpendiculară pe axa de vedere.

Flux optic




Flux optic

exemplu



Flux optic



Tehnici de estimare locală a mișcării

Aproape toate tehnicile de estimare a mișcării pot fi grupate într-una din următoarele categorii:

- bazate pe region matching
- bazate pe gradient
- bazate pe o analiză a frecvenței
- bazate pe urmărirea anumitor trăsături

Toate metodele au la bază estimarea locală a mișcării de tranzlație din imagine.


Block Matching

Metoda block matching este general aplicabilă unei regiuni rectangulare a cărei dimensiune a fost dinainte fixată. Se definește o suprafață de căutare pentru vectorul de deplasare. Fie ea:

$$|u| \leq \Delta_h \text{ și } |v| \leq \Delta_v \quad (4.42)$$

Ca o regulă generală, vectorii de deplasare acceptabili sunt multipli întregi ai perioadei de eșantionare spațiale sau a unei jumătăți de perioadă. Dacă dimensiunea blocului este de K linii și L coloane, mărimea suprafeței de căutare este $(K + 2\Delta_h)(L + 2\Delta_v)$. Numărul de deplasări posibile în același caz este de $(2\Delta_h + 1)(2\Delta_v + 1)$. De exemplu, pentru un deplasament maxim pe orizontală și verticală de 7 pixeli, numărul de deplasamente posibile este 225. După definirea suprafeței de căutare trebuie stabilit criteriul ce trebuie optimizat.

Block Matching



Modelul block matching

Criteriul cel mai frecvent utilizat este media valorii absolute a diferenței dintre cadrele deplasate:

$$(\hat{u}, \hat{v}) = \arg \min_{\substack{(u, v) \in Z^2 \\ |u| \leq \Delta_h, |v| \leq \Delta_v}} \sum_{i=0}^{K-1} \sum_{j=0}^{L-1} |I_{DFD}(i, j; u, v)| \quad (4.43)$$

sau media pătratelor diferențelor cadrelor deplasate:

$$(\hat{u}, \hat{v}) = \arg \min_{\substack{(u, v) \in Z^2 \\ |u| \leq \Delta_h, |v| \leq \Delta_v}} \sum_{i=0}^{K-1} \sum_{j=0}^{L-1} (I_{DFD}(i, j; u, v))^2 \quad (4.44)$$


sau valoarea normalizată a mediei pătratelor diferențelor cadrelor deplasate:

$$(\hat{u}, \hat{v}) = \arg \min_{\substack{(u, v) \in Z^2 \\ |u| \leq \Delta_h, |v| \leq \Delta_v}} \frac{\sum_{i=0}^{K-1} \sum_{j=0}^{L-1} (I_{DFD}(i, j; u, v))^2}{\sum_{i=0}^{K-1} \sum_{j=0}^{L-1} I^2(i, j; k)} \quad (4.45)$$

unde $I_{DFD}(i, j; u, v) = I(i, j; k) - I(i - u, j - v; k - 1)$ reprezintă diferența cadrului deplasat.

Deoarece primul criteriu este cel mai puțin costisitor, el este cel mai adesea utilizat.

Block Matching



Block Matching

Să presupunem că blocul de referință este de dimensiune $M \times N$ pixeli, iar deplasarea maximă este $\pm d$, în ambele direcții, orizontală și verticală. Vectorul de mișcare (u, v) se obține determinând blocul din cea de-a doua imagine, ce se potrivește cel mai bine cu cel de referință, realizând o căutare în interiorul ferestrei de dimensiune $(2d+1) \times (2d+1)$. Fereastra de căutare este centrată pe blocul de referință din prima imagine.

Cel mai direct algoritm BMA este algoritmul de căutare totală (FS). Acesta găsește vectorul de mișcare optimal dintre toți vectorii de mișcare din interiorul ferestrei. Dar el necesită un număr de $(2d+1)^2$ calcule pentru determinarea distanței dintre cele două blocuri și determinarea distanței minime. Aceste calcule complexe fac ca acest algoritm să nu poată fi folosit în aplicații de timp real. În acest sens, s-au conceput mai mulți algoritmi pentru a reduce complexitatea calculelor. Dintre aceștia amintim: căutare în trei pași, căutare 2D logaritmică, căutare ortogonală, căutare în cruce, căutare în patru pași, căutarea de tip gradient descend.


Block Matching



a)



b)



c)

Secvența “translating tree”; a) și b) doua cadre succesive;
c) fluxul optic determinat cu NFS pentru un bloc de 13




a)



b)




c)




d)


Secvența “Hamburg Taxi”; a) și b) cadrele 1 și 2;
fluxul optic NFS pentru c) bloc de 5 și d) bloc de 9




a)



b)




c)



d)

Secvența “salesman”; a) cadrul 1 și b) 5; fluxul optic pentru c) $d=7$ și d) $d=13$

Block Matching




Algoritmi de reducere a complexității căutării

Căutarea în trei pași

Metoda “three step search” (3SS) se bazează pe o abordare a căutării de la grosier la fin, ceea ce duce la o scădere logaritmică la fiecare pas.

Dimensiunea pasului inițial este jumătate din mărimea maximă a deplasării d .

Pentru fiecare pas se verifică nouă puncte, iar punctul de minim al unei măsuri devine centrul de plecare al pasului următor. Numărul de puncte care se verifică este: $[1 + 8\lceil \log_2(d + 1) \rceil]$



Algoritmi de reducere a complexității căutării


Căutarea logaritmică 2-D

Pasul inițial este de mărime $d/4$.

La fiecare pas, căutarea este făcută doar în cinci poziții care includ un punct de mijloc și patru puncte din două direcții principale, orizontală și verticală.

În primul pas, cele patru puncte utilizate se află la mijloc, între centrul suprafeței și marginile ei. Dacă optimul este în punctul de mijloc, suprafața de căutare este decrementată cu jumătate.

Procedura continuă până când suprafața de căutare ajunge la dimensiunile de 3×3 . În acest ultim pas, toate cele nouă poziții sunt testate pentru a determina poziția minimului.



Algoritmi de reducere a complexității căutării


Căutarea ortogonală

Aceasta tehnică (orthogonal search) constă într-o căutare prin perechi de pași orizontali și verticali, având o scădere logaritmică la fiecare pas.


Pasul inițial este $d/2$. Se începe cu o căutare pe orizontală și sunt verificați câte trei pixeli pe această direcție.

Minimul devine centru de căutare pe verticală, care de asemenea constă în verificarea a trei puncte. Apoi pasul descrește la jumătate și se reia algoritmul. Algoritmul se termină când pasul devine 1. În cazul general, algoritmul necesită





$[1 + 4(\log_2(d + 1))] \text{ puncte de căutare.}$




Aplicatii ale fluxului optic



Aplicatii ale fluxului optic



Tehnici de procesare a mișcării norilor din secvențe de imagini satelit





Introducere

- a observa, a înțelege și a prevedea fenomenele meteorologice
- meteorologia s-a dezvoltat datorită progresului științific și tehnologic
- sateliții meteorologici - imagini cu conținut ce variază în funcție de mărimile fizice măsurate
- tehnicile pot oferi asistența meteorologilor în vizualizarea și interpretarea secvențelor de imagini satelit

Problematika imaginilor meteorologice satelit


Tipuri de sateliți meteorologici




Sateliți pe orbite polare

NOAA 6-9

Altitudine	Înclinare	perioada de revoluție	decalaj	rezoluție spațială
850 km	99°	102 min.	259°5	$1.1 \times 1.1 \text{ km}^2$



Sateliți geostaționari




Achiziția imaginilor METEOSAT

METEOSAT 4-7


Denumirea canalului	vizibil	vapori de apă	infraroșu
banda spectrală [μm] - 12.5		0.45 - 1.0 5.7 - 7.1	10.5
detectori (+redundanți)	2(+2)	1(+1)	1(+1)
linii × pixeli pe linie	5000×5000	2500×2500	2500×2500
rezoluție la verticală [km ²]	2.5×2.5	5×5	5×5
frecvența de achiziție [min]	30	30	30
disponibilitatea imaginilor [TU] 24		7 – 17 0 – 24	0 –
biți per pixel	8		
viteza de transmisie la sol	333 kbps (normal)		2.7 Mbps (burst)

Achiziția imaginilor METEOSAT




Satelitul METEOSAT 7

Canalul vizibil



Sectorul C2




Full earth disk

Canalul vaporilor de apă

zonele închise
reprezintă regiuni
fără umiditate


zonele deschise,
regiuni cu
umiditate ridicată



Canalul infra-roșu

zonele închise
reprezintă regiuni
calde

zonele deschise
regiuni reci



Clasificarea norilor (de interes în segmentare)

In funcție de altitudine:

- înalți (6-12 km): cirrus, cirrostratus, cirrocumulus, cumulonimbus
- medii (2-6 km): altostratus, altocumulus
- joși (0-2 km): stratus, stratocumulus, cumulus



a)



b)


Tipuri de formațiuni noroase: a) nori înalți (cirrus);
b) nori medii (altocumulus)



Nori de joasă altitudine (stratus)

Dificultăți legate de interpretarea imaginilor satelit

1. Multistratificare






Dificultăți legate de interpretarea imaginilor satelit (cont.)

2. Lipsa de contrast termic



Dificultăți legate de interpretarea imaginilor satelit (cont.)

3. Evoluția rapidă a fenomenelor meteo




Dificultăți legate de interpretarea imaginilor satelit (cont.)

4. Inversiune a contrastului termic



Secvență de test



Secvență METEOSAT infraroșu
din 21.04.2003 9:30-14:00 GMT


Adaptarea metodei Block Matching la specificul imaginilor satelit (cont.)

Rezultate

Vectorii de mișcare

algoritmul

block-matching FS




Vectorii de mișcare

metoda celui mai

bun candidat


neadaptat



Adaptarea metodei Block Matching la specificul imaginilor satelit (cont.)


Rezultate

Segmentarea
imaginii de la ora
11:00 GMT






Vectorii de mişcare

metoda celui mai
bun candidat
adaptat



Rezultate (cont.)

detalierea unei
porțiuni din secvența
anterioară



Secvența
METEOSAT

Secvența
segmentată

Secvența
vectorilor de
mișcare

Fluxul optic pentru sectorul C2

