


Klasifikace pomocí Fourierovských deskriptorů

Jan Bařtipán / A03043 / bartipan@students.zcu.cz

Zadání

- Fourierovský popis ploch – klasifikace objektů s jednoduchými tvary pomocí tvarových charakteristik – invariantů
- příznakový vektor sestaven z invariantů pro definovaný počet harmonických, metoda klasifikace – $\min \Delta_j$, pro $\forall j$, od vzoru D_j jako reprezentanta třídy objektů T_j

Hranice objektu



- Pro popis objektu jsem vyšel z hraničních křivek popisovaného objektu

Fourierova transformace

- Koeficienty jednotlivých souřadnic transformujeme FT:

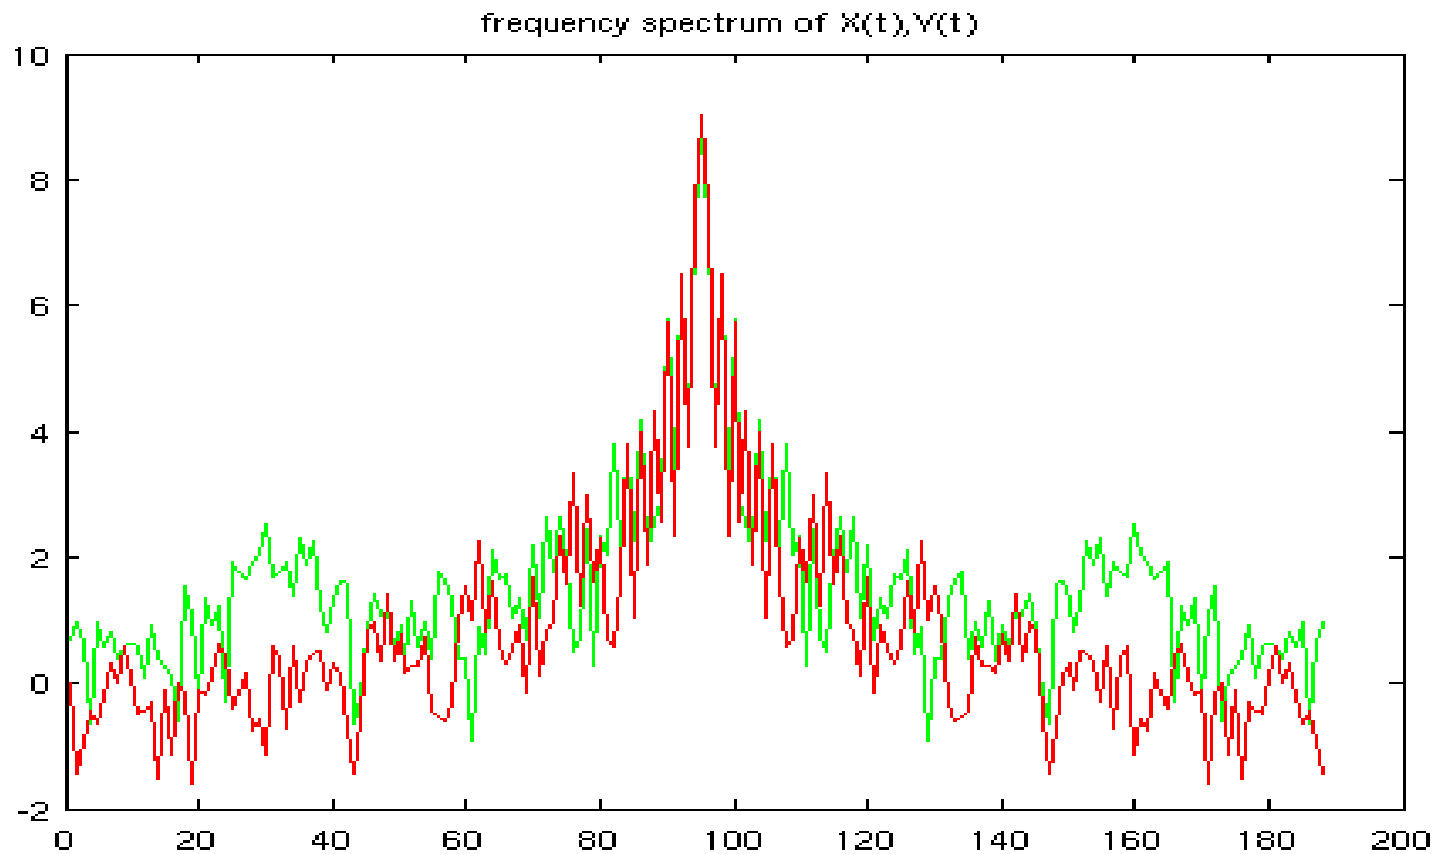
$$a_{xi} = \sum_{k=1}^n x_k \cdot \cos\left(\frac{2\pi k i}{n}\right)$$

$$b_{xi} = \sum_{k=1}^n x_k \cdot \sin\left(\frac{2\pi k i}{n}\right)$$

$$a_{yi} = \sum_{k=1}^n y_k \cdot \cos\left(\frac{2\pi k i}{n}\right)$$

$$b_{yi} = \sum_{k=1}^n y_k \cdot \sin\left(\frac{2\pi k i}{n}\right)$$

Fourierova transformace



Inverzní Fourierova transformace

- Inverzní transformace:

$$x_i = \frac{1}{2} \cdot a_{x0} + \sum_{k=1}^n \left[a_{xk} \cdot \cos\left(\frac{2\pi ki}{n}\right) + b_{xk} \cdot \sin\left(\frac{2\pi ki}{n}\right) \right]$$

$$y_i = \frac{1}{2} \cdot a_{y0} + \sum_{k=1}^n \left[a_{yk} \cdot \cos\left(\frac{2\pi ki}{n}\right) + b_{yk} \cdot \sin\left(\frac{2\pi ki}{n}\right) \right]$$

Význam koeficientů

- Inverzní transformace pro první čtveřici koeficientů:

$$x(t) = \frac{1}{2} \cdot a_{x0} + a_{xl} \cdot \cos(2\pi \cdot t) + b_{xl} \cdot \sin(2\pi \cdot t)$$


$$y(t) = \frac{1}{2} \cdot a_{y0} + a_{yl} \cdot \cos(2\pi \cdot t) + b_{yl} \cdot \sin(2\pi \cdot t)$$

$$t \in \langle 0, 1 \rangle$$

Význam koeficientů

- První „čtveřice“ koeficientů určuje těžiště (střed) objektu
- Druhá čtveřice koeficientů určuje tvar elipsy
- Další čtveřice zpřesňují tvar hranice

Význam koeficientů



Odvození deskriptorů

- Na poloze je závislá jen první čtveřice koeficientů, která vyjadřuje těžiště objektu

$$a_{x0}, a_{y0}$$

$$b_{x0} = 0, b_{y0} = 0$$

- Ostatní koeficienty jsou na poloze nezávislé

$$a_{xi}, b_{xi}, a_{yi}, b_{yi}, i = 1, 2, \dots, n-1$$

Odvození deskriptorů

- Protože dvojice koeficientů a_{xi} , b_{xi} ve skutečnosti představuje komplexní číslo $a_{xi} + b_{xi}j$, můžeme je vyjádřit v polárních souřadnicích jako:

$$A_{xi} = \sqrt{a_{xi}^2 + b_{xi}^2}, A_{yi} = \sqrt{a_{yi}^2 + b_{yi}^2}$$

$$\phi_{xi} = \arccos\left(\frac{a_{xi}}{A_{xi}}\right), \phi_{yi} = \arcsin\left(\frac{a_{yi}}{A_{yi}}\right)$$

Odvození deskriptorů

- Koeficienty $A_{xi}, A_{yi}, i=1 \dots n-1$ jsou závislé na změně měřítka i rotaci

- Upravíme koeficienty:

$$AA_{xi} = \frac{A_{xi}}{A_{x1}}$$

- Jsou nezávislé na měřítku

$$AA_{yi} = \frac{A_{yi}}{A_{y1}}$$

$$i=2 \dots n-1$$

Odvození deskriptorů

- Poslední úprava:

$$D_i = \sqrt{AA_{xi}^2 + AA_{yi}^2}$$
$$i = 2 \dots n - 1$$

- Koeficienty D_i jsou nezávislé na rotaci (posunutí i změně měřítka)

Algoritmus klasifikace

- Máme třídy objektů, reprezentované příznakovým vektorem $d_i = (D_2^i, D_3^i, \dots, D_k^i)$

- Máme příznakový vektor klasifikovaného objektu

$$\hat{d} = (\hat{D}_2, \hat{D}_3, \dots, \hat{D}_k)$$

- Objekt zařadíme do třídy x jako:

$$x = \operatorname{minarg}_{\forall i} \{ \|d_i - \hat{d}\| \}$$

Experiment #1

- Jako trénovací data posloužila skupina velkých písmen A..Z, patkového fontu generované s konstantní velikostí, natočením a posunutím
- Testovací data byla různě veliká (cca 80%-200% velikosti vzorového fontu), různě posunutá a natočená.
- Příznakový vektor má velikost $k = 8$


Experiment #1

- Vzorová (26) a testovací (100) data:

A	B	C	D	B	Z
E	F	G	H	G	J
I	J	K	L		
M	N	O	P		

Experiment #1

Good recognised



- Celková úspěšnost – 54%, rozpoznáno 7 tříd uspokojivě.


Experiment #2

- Použít bezpatkový font, zvětšen font vzorových dat, testovací data ve velikosti 100% - 250%
- Velikost příznakového vektoru zůstává nezměněna

A B C D
E F G H
I J K L
M N O P

Experiment #2

Good recognition ratio




- Celková úspěšnost – 71%, 8 tříd rozpoznáno na 100%, další 3 na 90%

Experiment #3

- Zdvojnásobena velikost příznakového vektoru, $k=16$
- Ostatní podmínky stejné jako u druhého experimentu.

Experiment #3

Good recognized



- Úspěšnost se nepatrně zvedla na 72%, rozrostl se však počet tříd klasifikovaných na 100% (10 tříd) a 90% (+2)

Závěr

- Jednoduchý klasifikátor s relativně dobrou úspěšností
- Problémem je rasterizace v kombinaci s rotací – vzniká nepřesnost
- Zlepšení:
 - Více vzorových reprezentantů pro třídu
 - Sofistikovanější algoritmus klasifikace