

# Štatistická analýza tvaru a obrazu

Interdisciplinárny prístup  
postavený na matematických a štatistických základoch

Stanislav Katina

<sup>1</sup>Ústav matematiky a štatistiky  
Přírodovědecká fakulta  
Masarykova Univerzita v Brně

Tento učební text vznikl za přispění Evropského sociálního fondu a státního rozpočtu ČR prostřednictvím Operačního programu Vzdělávání pro konkurenceschopnost v rámci projektu Univerzitní výuka matematiky v měnícím se světě (CZ.1.07/2.2.00/15.0203).




INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Stanislav Katina

Štatistická analýza tvaru a obrazu


## Shape Analysis—Interdisciplinary View



Stanislav Katina

Štatistická analýza tvaru a obrazu

## Shape Analysis Vision $\approx$ My Partial Research Tree



Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analýza obrazu

Digitálny obraz

### Definition (Digitálny obraz – definícia)

Digitálny obraz  $I$  je dvoj-dimenzionálna funkcia prirodzených čísel vrátane nuly  $\mathbb{N}_0 \times \mathbb{N}_0$  do možných hodnôt intenzity z množiny  $\mathbb{P}$ , teda

$$I : \mathbb{N}_0^2 \rightarrow \mathbb{P}; \text{ kde } u, v \in \mathbb{N}_0 \text{ a } I(u, v) \in \mathbb{P}.$$

**Veľkosť obrazu** je charakterizovaná jeho **šírkou**  $M$  (počet stĺpcov) a **výškou**  $N$  (počet riadkov) **obrazovej matice**  $I$ , kde  $u_{\max} = M - 1$ ,  $v_{\max} = N - 1$  a rozmery obrazu sú  $M \times N$  **pixelov** (obrazových elementov). Čísla  $M, N$  sú zvyčajne rovné  $2^k$ , kde  $k$  sa nazýva **bitová hĺbka**. Obrazový súradnicový systém sa riadi nasledovnými zásadami

- 1 y-ové súradnice idú zhora dole,
- 2 stred súradnicovej sústavy je bod  $(u = 0, v = 0)$  ležiaci v ľavom hornom rohu.

Potom transformácia z obrazovej do karteziánskej súradnicovej sústavy bude nasledovná  $I(u, v) \rightarrow I(N - 1 - v, u)$ .

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Definition (Typy digitálneho obrazu)

- 1 Obraz v odtienoch sivej** – obraz pozostávajúci z jedného komponentu reprezentovaného intenzitou (nazývanou aj jas alebo hustota), ktorej hodnoty patria množine  $\{0, 1, \dots, 2^k - 1\}$ , zvyčajne  $2^k - 1 = 255$ ; ( $k = 8$ ) bitov (1 byte); 0 reprezentuje minimálny jas (čierna farba) a 255 the maximálny jas (biela farba).
- 2 Binárny obraz** – obraz, ktorý je špeciálnym typom obrazu v odtieni sivej, kde intenzita môže nadobúdať dve hodnoty nula a jedna (na pixel) a kóduje **farby čierna a biela**.
- 3 RGB farebný obraz** – obraz zložený z troch komponentov nazývaných aj primárne farby—**červená, zelená a modrá (RGB)**; typicky zaberajúce  $k = 8$  bitov pre každý farebný komponent.

## Definition (RGB farebný obraz)

RGB je **aditívny systém farieb**, čo znamená, že všetky farby sú vytvárané pridávaním primárnych farieb  $k$  základnej čiernej farbe. RGB môžeme vizualizovať ako troj-dimenzionálnu jednotkovú kocku (**RGB kocka**), kde osi tohoto systému nazývame osi primárnych farieb. Rozsah RGB hodnôt je  $[0, C_{\max}]$ . Každá možná farba korešponduje bodu  $C_i$  v RGB kocke

$$C_i = (R_i, G_i, B_i), \text{ kde } 0 \leq R_i, G_i, B_i \leq C_{\max}.$$

**Rovinné usporiadanie farieb v skutočnom farebnom RGB obraze** – jednotlivé farebné komponenty ležia v separátnych maticiach rovnakých rozmerov a funkcia intenzity má tvar  $I = (I_R, I_G, I_B)$ . Potom RGB farebný

obraz  $I$  je pole  $M \times N \times 3$  typu  $I = (I_R : I_G : I_B)$ , kde  $I_R, I_G$ , a  $I_B$  sú  $M \times N$  matice. Element  $(u, v, c)$  pola je definovaný ako  $I_c(u, v)$ , kde  $c = R, G$  a  $B$  komponent. RGB metrika (vzdialenosť) nezodpovedá našmu zrakovému vnímaniu, t.j. RGB metrika a zrakové vnímanie sú neproporcionálne.

## Definition (Transformácia RGB farieb do sivej škály)

Výsledkom transformácie RGB farieb do sivej škály je **iluminácia (jas) v sivej škále** definovaná ako

$$Y_g = \text{Avg}(R, G, B) = \frac{R + G + B}{3}.$$

Keďže *červená a zelená sú vnímané ako oveľa jasnejšie ako modrá, výsledný obraz sa nám bude zdať tmavý v červených a zelených oblastiach a príliš svetlý v modrých*. Preto je potrebné zaviesť **váženú ilumináciu (jas) v sivej škále**

$$Y_g = \text{Lum}(R, G, B) = w_R R + w_G G + w_B B,$$

kde  $w_R = 0.2125$ ,  $w_G = 0.7154$ , and  $w_B = 0.0720$  sú odporúčané váhy.

**Bezfarebný (sivý) obraz** definujeme ako obraz, kde každý RGB komponent má rovnakú hodnotu, t.j.

$$I_g(u, v) = \begin{pmatrix} R_{u,v}^{(g)} \\ G_{u,v}^{(g)} \\ B_{u,v}^{(g)} \end{pmatrix} \leftarrow \begin{pmatrix} Y_g \\ Y_g \\ Y_g \end{pmatrix}, \text{ kde } Y_g = \text{Lum}(R, G, B).$$

## Definition (Obrazový histogram)

**Obrazový histogram** je histogram popisujúci početnosti hodnôt intenzity (jasu) obrazu. Histogram  $h$  obrazu v odtieňoch sivej  $I$  s hodnotami intenzity  $I(u, v) \in [0, K - 1]$  obsahuje  $K$  hodnôt, kde pre typický 8 bitový obraz  $K = 2^8 = 256$ . Jednotlivé zložky histogramu sú definované ako

$$h(i) = \text{počet pixelov } v \text{ } I \text{ s intenzitou } i, \text{ pre všetky } i \in [0, K - 1],$$

$$h(i) = \text{card} \{ (u, v) | I(u, v) = i, i \in \mathbb{P} \}.$$

Interpretácia:

- 1 expozícia** – *pod- a preexponovaný obraz, dobre exponovaný obraz,*
- 2 kontrast** – rozsah hodnôt intenzity použitý v danom obraze; *plnokontrastový obraz*—efektívne používa celkový možný rozsah hodnôt intenzity  $a \in [a_{\min}, a_{\max}]$  alebo  $\{0, 1, \dots, K - 1\}$  (čierna–biela)
- 3 dynamický rozsah** – počet rozdielnych hodnôt intenzity v obraze (ideálne všetkých  $K$  hodnôt); pokiaľ máme  $a \in [a_{\min} < a_{\text{low}}, a_{\text{high}} < a_{\max}]$  *maximálne možný dynamický rozsah* je možné dosiahnuť použitím všetkých možných hodnôt intenzity

### Definition (Chyby alebo artefakty obrazu)

- 1 **chyby saturácie** – ideálne by mal byť rozsah kontrastu senzora väčší ako rozsah intenzity svetla snímanej scény, potom by bol histogram hladký na oboch koncoch; realita – často lesklé alebo tmavé plochy; histogram je **saturovaný** na koncoch; významné hroty na koncoch pri pod- a preexponovaných obrazoch
- 2 **chyby transformácie** – ideálne je rozdelenie intenzity hladké globálne ako aj lokálne; realita – zriedka v originálnom obraze, ale často v transformovanom obraze; **zvyšovanie kontrastu** vedie ku separácii hodnôt intenzity (diskretizácii; tvorbe dier); **znižovanie kontrastu** vedie ku zlučovaniu hodnôt intenzity, ktoré boli predtým rozdielne (diskretizácia; tvorba hrotov)
- 3 **chyby kompresie** – napr. počas kompresie do GIF je dynamický rozsah redukovaný na niekoľko hodnôt intenzity (**kvantovanie farieb**), tzv. **líniová štruktúra histogramu**
- 4 **chyby individuálnych komponent** – v ilumináčnom histograme (hist. intenzity sivej farby) neviditeľné chyby, ktoré sa objavujú v histogramoch jednotlivých komponent (**presaturovanie modrého komponentu**)

### Definition (Bodové operácie)

**Homogénna bodová operácia (globálna)** – modifikácia intenzity bez zmeny veľkosti, geometrie alebo lokálnych štruktúr obrazu. Hodnoty intenzity  $a$  sú transformované na nové hodnoty  $a'$  použitím funkcie  $f(a)$ ,

$$a' \leftarrow f(a) \text{ alebo } I'(u, v) \leftarrow f(I(u, v)), \text{ pre } \forall (u, v),$$

kde  $f(\cdot)$  je **nezavislá na súradniciach**  $(u, v)$ , t.j. je všade rovnaká, napr.

- 1 globálna transformácia intenzity (jasu), kontrastu alebo farby
- 2 globálne kvantovanie obrazu a thresholding

Avšak funkcia  $g(\cdot)$  ako **nehomogénna bodová operácia (lokálna)** berie do úvahy aj súradnice  $(u, v)$ , ale netransformuje ich na iné; t.j.

$$a' \leftarrow g(a, u, v) \text{ alebo } I'(u, v) \leftarrow g(I(u, v), u, v).$$

Napr.

- 1 lokálna transformácia intenzity (jasu), kontrastu alebo farby
- 2 lokálne kvantovanie obrazu a thresholding

### Definition (Lineárne bodové operácie)

**Lineárnu bodovú operáciu** definujeme ako

$$f_{lio}(a) = k \cdot a + l,$$

kde  $k$  je nejaká **škálovacia konštanta intenzity** and  $l$  je **aditívna vyrovnávací konštanta intenzity** obrazu.

**Saturačné (urezavacie, winsorizačné) podmienky** definujeme nasledovne

- 1 ak  $f_{lio}(a) < 0$ , potom  $f_{lio}(a) = 0$  (if  $(a < 0)$  a  $\leftarrow 0$ )
- 2 ak  $f_{lio}(a) > K - 1$  potom  $f_{lio}(a) = K - 1$  (if  $(a > K-1)$  a  $\leftarrow K-1$ )

### Definition (Aditívne vyrovnávanie obrazu)

**Aditívne vyrovnávanie obrazu:** nech  $k = 1$ ,  $l \in \mathbb{Z}$ ,  $|l| \leq K - 1$

$$f_{lio}(a) = a + l,$$

kde

- 1  $l \in \mathbb{Z}$ , pretože chceme, aby intenzita bola kvantovaná z  $\{0, 1, \dots, K - 1\}$
- 2  $|l| \leq K - 1$ , pretože inak by bola intenzita mimo povoleného rozsahu
- 3 ak  $l > 0$ , potom transformovaný obraz bude **svetlejší** ako pôvodný
- 4 ak  $l < 0$ , potom transformovaný obraz bude **tmavší** ako pôvodný
- 5  $l$  predstavuje **posun histogramu doľava alebo doprava**

## Definition (Škálovanie obrazu)

**Škálovanie obrazu:** nech  $l = 0$  a  $k > 0$ , potom

$$f_{\text{io}}(a) = k \cdot a,$$

kde

- 1  $k > 0$ , pretože  $f_{\text{io}}(a)$  musí byť kladné
- 2 nie je nutné, aby  $k \in \mathbb{Z}$ , pretože by sme mali len veľmi málo použiteľných možností
- 3 praktické zaokrúhľovanie (v prípade potreby)  $f_{\text{io}}(a) = \lfloor k \cdot a + 0.5 \rfloor$
- 4 ak  $k > 1$ , potom intenzita  $f_{\text{io}}(a)$  pokryje **širší interval hodnôt** ako  $a$
- 5 ak  $k < 1$ , potom intenzita  $f_{\text{io}}(a)$  pokryje **užší interval hodnôt** ako  $a$
- 6 **škálovanie naťahuje alebo stláča histogram v smere osi  $x$**

## Definition (Negatív obrazu)

**Negatív obrazu:** nech  $k = -1$  a  $l = K - 1$ , potom

$$f_{\text{io}}(a) = -a + (K - 1),$$

kde

- 1 škálovanie použitím  $k = -1$  spôsobí **reverziu (flip) histogramu v smere osi  $x$**
- 2 aditívna konštanta  $l = K - 1$  spôsobuje, že **všetky transformované hodnoty sú kladné a patria do povoleného rozsahu**

## Definition (Autokontrast)

**Autokontrast:**

$$f_{\text{io}}(a) = k \cdot (a - c) + l, \text{ kde } l = a_{\text{min}}, c = a_{\text{low}}, k = \frac{a_{\text{max}} - a_{\text{min}}}{a_{\text{high}} - a_{\text{low}}}, a_{\text{low}} \neq a_{\text{high}},$$

a intenzita je modifikovaná tak, aby jej hodnoty pokryli celý možný rozsah povolených hodnôt.

## Definition (Thresholding)


**Thresholding** je špeciálnym typom kvantovania obrazu, ktoré separuje intenzitu do dvoch tried v závislosti na **prahovej konštante**  $a_{\text{th}}$ . **Prahová funkcia**  $f_{\text{threshold}}(a)$  kategorizuje pixely do dvoch skupín, ktorým zodpovedajú hodnoty intenzity  $a_0$  a  $a_1$ , nasledovne

$$f_{\text{threshold}}(a) = \begin{cases} a_0 & \text{pre } a < a_{\text{th}} \\ a_1 & \text{pre } a \geq a_{\text{th}} \end{cases}, \text{ kde } 0 < a_{\text{th}} \leq a_{\text{max}}$$

Typickými aplikáciami sú

- 1 **binarizácia intenzity obrazu** s hodnotami  $a_0 = 0$  a  $a_1 = 1$ , ktorá v  $\mathbb{R}$  bude vyzeráť nasledovne  
`a[which(a < a.th)] <- 0; a[which(a >= a.th)] <- 1.`
- 2 thresholding je najefektívnejší pri **bimodálnom histograme** – charakterizuje objekt a pozadie majúce rôznu priemernú intenzitu – tmavý objekt a svetlé pozadie alebo svetlý objekt a tmavé pozadie
- 3 cieľ – **separovať objekt od pozadia** alebo nájsť **obrysy objektu**

## Example (R logo)

Majme  $\mathbb{R}$  logo  (rozmiery  $77 \times 101$  pixelov)—uložené ako **PPM (Portable Pixel Map, portable pixmaps)**. Aj napriek tomu, že ide o neefektívny formát rastrovaneho obrazu, je veľmi jednoduchý z hľadiska spracovania obrazu, a preto sa často používa.


- 1 Načítajte a zobrazte toto logo  $M$  v  $\mathbb{R}$ .
- 2 Inveretujte  $\mathbb{R}$  (červený) komponent obrazu  $M$ .
- 3 Inveretujte  $\mathbb{G}$  (zelený) komponent obrazu  $M$ .
- 4 Inveretujte  $\mathbb{B}$  (modrý) komponent obrazu  $M$ .
- 5 Zvýraznite  $\mathbb{R}$  komponent obrazu  $M$ .
- 6 Odstráňte zelený komponent obrazu  $M$ .
- 7 Transformujte  $M$  do sivej škály.
- 8 Zvýraznite kontrast  $M$  v sivej škále pomocou funkcie  $f(a) = a^k, k = 2$ .

## Example 10

Digitálny obraz

Riešenia:

- 1 knižnica `library(pixmap)`, príkaz  
`M <- read.pnm(system.file("pictures/logo.ppm",  
package="pixmap")) [1]`
- 2 `M1 <- M; M1@red <- 1-M@red; plot(M1)`
- 3 `M1 <- M; M1@green <- 1-M@green; plot(M1)`
- 4 `M1 <- M; M1@blue <- 1-M@blue; plot(M1)`
- 5 `M1 <- M; M1@red <- 0.5 + M@red/2; plot(M1)`
- 6 `M1 <- M; M1@green <- matrix(0,77,101); plot(M1)`
- 7 `M1 <- as(M,"pixmapGrey"); M2 <- M1; plot(M2)`
- 8 `M2 <- M1; M2@grey <- (M2@grey)^2; plot(M2)`



Obrázok: Bodové operácie s obrazom R logo

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 11

Digitálny obraz

### Example (Binarizácia lastúry)

Majme lastúru (*Mytilus* sp.) uloženú ako PPM.

- 1 Načítajte obraz lastúry `M` v R.
- 2 Transformujte `M` do sivej škály a zobrazte použitím funkcie `plot()`.
- 3 Binarizujte obraz `M` pri thresholde 0.1 a vypočítajte počet pixelov lastúry.
- 4 Binarizujte obraz `M` pri thresholde 0.3 a vypočítajte počet pixelov lastúry.
- 5 Binarizujte obraz `M` pri thresholde 0.9 a vypočítajte počet pixelov lastúry.

Riešenia:

- 1 `library(pixmap); M <- read.pnm("mytilus.ppm")`
- 2 `M <- as(M,"pixmapGrey"); M1 <- M@grey plot(M,main="Grey  
scale image")`
- 3 `M1 <- M@grey; M@grey[which(M1 >= 0.1)] <- 1; a.th <- .1  
M@grey[which(M1 < a.th)] <- 0  
plot(M,main="Binary image, threshold = 0.1")  
length(M@grey[which(M1 < a.th)])`

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 11

Digitálny obraz

Grey scale image



Binary image, threshold = 0.3



Binary image, threshold = 0.1



Binary image, threshold = 0.9



Obrázok: Lastúra *Mytilus* sp. v sivej škále (vľavo hore) a binarizovaná pri rôznych hodnotách konštanty  $a_{th} = 0.1, 0.3, 0.9$

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 12

Digitálny obraz

### Example (Binarizácia lastúry, pokrač.)

Majme lastúru (*Mytilus* sp.) uloženú ako JPEG.

- 1 Transformujte obraz z formátu JPEG do formátu PPM.
- 2 Načítajte obraz lastúry `M` v R.
- 3 Transformujte `M` do sivej škály a zobrazte použitím funkcie `image()`.  
Pozn.: Treba si uvedomiť, že **Pixel Aspect Ratio (PAR)**, kde PAR je rovné pomeru šírky a výšky pixela, nemusí byť rovné jednej, ale napr. 2/3, 3/4 alebo 9/16, čo sa dá ľahko ošetriť pomocou argumentu `asp=PAR` vo funkcii `image()`. Funkcia `plot()` priamo načítava PAR zo súboru PPM, a preto táto korekcia nebola potrebná. PAR je pre lastúru rovný 9/16. Na zobrazenie `M` použite všetky možné odtiene sivej (8-bitová škála sivej).
- 4 Na zobrazenie `M` použite len tri odtiene sivej (2-bitová škála sivej).
- 5 Na zobrazenie `M` použite len dva odtiene sivej (1-bitová škála sivej, monochromatický obraz).
- 6 Zobrazte `M` použitím funkcie `contour()` bez korekcie PAR.

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 12


Digitálny obraz

Riešenia:

```
1 library(pixmap); library(rimage)
  shell("convert mytilus.jpg mytilus.ppm")
2 M <- read.pnm("mytilus.ppm")
3 M <- as(M, "pixmapGrey")
  image(t(M@grey[dim(M@grey)[1]:1,]), col=grey(0:255/255),
        asp=9/16, axes=FALSE, main="Gray-scale: 8-bits")
4 image(t(M@grey[dim(M@grey)[1]:1,]), col=grey(0:3/3),
        asp=9/16, axes=FALSE, main="Gray-scale: 2-bits")
5 image(t(M@grey[dim(M@grey)[1]:1,]), col=grey(0:1/1),
        asp=9/16, axes=FALSE, main="Monochrome: 1-bits")
6 contour(t(M@grey[dim(M@grey)[1]:1,]), axes=FALSE)
  title(main="Contour plot")
```

## Example 12

Digitálny obraz



**Obrázok:** Lastúra *Mytilus* sp. v 8-bitovej sivej škále (vľavo hore), v 2-bitovej sivej škále (vľavo dole), v 1-bitovej sivej škále (vpravo hore) a kontúrový obraz použitím nesprávneho PAR

## Example 13

Digitálny obraz

Example (Hmyzie krídlo, histogram intenzity a extrakcia súradníc landmarkov)

Majme hmyzie krídlo uložené ako **JPEG**.

- 1 Načítajte obraz krídla  $M$  v R.
- 2 Transformujte obraz z formátu JPEG do formátu PPM.
- 3 Transformujte  $M$  do sivej škály, zobrazte histogram intenzity  $M$  a zobrazte  $M$  použitím funkcie `plot()`.
- 4 Zvýraznite kontrast  $M$  v sivej škále pomocou funkcie  $f(a) = a^k$ ,  $k = 3$ , zobrazte histogram intenzity  $M$  a zobrazte použitím funkcie `plot()`.
- 5 Použitím funkcie `locator()` lokalizujte 5 landmarkov (viď. obrázok), označte ich ako  $+$  a extrahujte ich súradnice. Do obrázku dopíšte čísla landmarkov 1 – 5.
- 6 Lokalizujte hranice časti krídla (viď. obrázok) ako landmarky 6 – 10 použitím funkcie `locator()` a vykreslite polygón vnútri konvexného obalu týchto landmarkov pomocou funkcie `polygon()`.
- 7 Čo sme pri extrakcii landmarkov zanedbali?

## Example 13


Digitálny obraz

Riešenia:

```
1 library(pixmap); library(rimage)
  M <- read.jpeg("wing.jpg")
2 shell("convert wing.jpg wing.ppm")
  M <- read.pnm("wing.ppm")
3 M1 <- M; M1 <- as(M1, "pixmapGrey")
  hist(M1@grey)
  plot(M1, main="Grey scale image")
4 M1@grey <- (M1@grey)^3
  hist(M@grey)
  plot(M, main="Grey scale image brightness modified")
5 plot(M)
  lok <- locator(5, type="p", pch=3)
  text(lok, pos=2, labels=1:5)
6 lok <- locator(5, type="l")
  polygon(lok, density=12)
```

## Example 13

Digitálny obraz



**Obrázok:** Histogramy (prvý riadok vľavo) a obrázky v sivej škále, modifikovanej sivej škále (druhý riadok vľavo) obrázu hmyzie krídlo a obraz hmyzie krídlo v sivej škále s lokalizovanými landmarkami (vpravo)

Stanislav Katina

Štatistická analýza tvaru a obrázu

## Example 14

Digitálny obraz

### Example (Sánka, negatív obrazu a extrakcia súradníc landmarkov)

Majme sánku uloženú ako **JPEG**.

- 1 Načítajte obraz sánky  $M$  v  $R$ .
- 2 Transformujte  $M$  do sivej škály a zobrazte  $M$  použitím funkcie `plot()`.
- 3 Invertujte obraz  $M$  v sivej škále (vytvorte negatív obrazu) a zobrazte použitím funkcie `plot()`.
- 4 Použitím funkcie `locator()` odmerajte vzdialenosť 1cm.
- 5 Použitím funkcie `locator()` lokalizujte 10 landmarkov (viď. obrázok), označte ich ako  $o$ . Preškálujte extrahované súradnice na správnu mierku.

Riešenia: `library(rimage)`


- 1 `M <- read.jpeg("jawd.jpg")`
- 2 `M <- rgb2grey(M); plot(M)`
- 3 `M <- 1 - M; plot(M)`
- 4 `lok <- locator(2, type="o", pch=8, lwd=2, col="grey60", lty="11")`  
`scale.one <- sqrt(sum(diff(lok$x)^2 + diff(lok$y)^2))`
- 5 `b <- locator(10, type="p")`  
`conf.mat <- rbind(b$x, b$y) / scale.one`

Stanislav Katina

Štatistická analýza tvaru a obrázu

## Example 14

Digitálny obraz



**Obrázok:** Obrázok sánky v RGB škále (prvý riadok vľavo), v sivej škále (prvý riadok v strede), negatív obrazu v sivej škále (prvý riadok vpravo) a negatív s lokalizovanými landmarkami (druhý riadok)

Stanislav Katina

Štatistická analýza tvaru a obrázu

## Analýza obrázu

Uzavreté obrysy

### Definition (Automatická extrakcia uzavretých obrysov a reťazové kódovanie)

**Objekt** v rovine je reprezentovaný jeho **vnútrom** a **obrysom**. Obrys môžeme automaticky extrahovať pomocou **reťazového (sekvenčného, Freemanovho) kódovania** definovaného pomocou sekvencie smerových zmien na diskretnom rastrovnom obraze.

- 1 definujeme **štartovací bod**  $\mathbf{x}_S$  vnútri objektu  $\mathcal{R}$  v rovine
- 2 uzavretý obrys je definovaný pomocou sekvencie bodov  $\mathbf{c}_{\mathcal{R}} = [\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_{C-1}]$ , kde  $\mathbf{x}_i = (u_i, v_i)$
- 3 jednotlivé elementy sekvencie  $\mathbf{c}'_{\mathcal{R}} = [c'_0, c'_1, \dots, c'_{C-1}]$  definujeme ako  $c'_i = \text{Code}(\Delta u_i, \Delta v_i)$ , kde

$$(\Delta u_i, \Delta v_i) = \begin{cases} (u_{i+1} - u_i, v_{i+1} - v_i) & \text{pre } 0 \leq i < C - 1 \\ (u_0 - u_i, v_0 - v_i) & \text{pre } i = C - 1 \end{cases}$$

a  $\text{Code}(\Delta u_i, \Delta v_i)$  definujeme pomocou **8-pixelového susedstva**

$\Delta u$	1	1	0	-1	-1	-1	0	0		3	2	1
$\Delta v$	0	1	1	1	0	-1	-1	-1		4	pixel	0
$\text{Code}(\Delta u_i, \Delta v_i)$	0	1	2	3	4	5	6	7		5	6	7

Stanislav Katina

Štatistická analýza tvaru a obrázu

### Algoritmus:

1.  $I$ : binarizovaný obraz;  $I(u, v) = 0$  (objekt),  $I(u, v) = 1$  (pozadie)
2. lokalizujú súradnice štartovacieho pixela,  $\mathbf{x}_S = (x_S, y_S)$ , vnútri objektu tak, aby bolo jeho 4-pixelové susedstvo v objekte; potom transformujú obrazové súradnice od karteziánskych, kde  $\mathbf{x}_S = (\dim(I)_{(1)} - y_S, x_S)$  (pozri slajd "Digitálny obraz – definícia")
3. fixujú  $a = 1$  (štartovací bod pre pohyb z jedného pixela do druhého, kde index pixela korešponduje  $a$ , ktoré sa zvýši o jednotku, keď je nájdený ďalší pixel proti smeru hodinových ručičiek),  $S = 6$  (štartovací bod; pixel č.6) a  $SS = \text{NA}$  (reťazec);  $\mathbf{x} = 0$ ;  $\mathbf{y} = 0$  (štartovacie body;  $x$ - a  $y$ -ové súradnice); nech matica  $\Delta$  má riadky  $\Delta u$  a  $\Delta v$ , potom  $\mathbf{D} = (\Delta_{(\cdot,8)}; \Delta_{(\cdot,7)}; \Delta_{(\cdot,6)}; \Delta_{(\cdot,5)})$ , kde  $\Delta_{(\cdot,i)}$  je  $i$ -ty stĺpec matice  $\Delta$
4. while  $(\mathbf{x}_{(a)}, \mathbf{y}_{(a)}) \neq \mathbf{x}_S$  (pokiaľ sa dosiahne opať štartovací bod) or dĺžka vektora  $\mathbf{x}$  je menšia ako 3 (vyhneme sa nekonečnej slučke) choď na (5) – (6)
5. if  $|I(x_S + \mathbf{D}_{(1,S+1)}, y_S + \mathbf{D}_{(2,S+1)}) - I(x_S, y_S)| < \text{threshold}$ , potom  $a = a + 1$   
 $\mathbf{x}_{(a)} = x_S$ ;  $\mathbf{y}_{(a)} = y_S$   
 $\mathbf{x}_S = \mathbf{x}_S + \mathbf{D}_{(\cdot,S+1)}$   
 $SS_{(a)} = S + 1$ ;  $S = (S + 7) \bmod 8$  (skontroluj pixel 5 a choď na pixel 5)

### Algoritmus (pokrač.):

6. if else  $|I(x_S + \mathbf{D}_{(1,S+2)}, y_S + \mathbf{D}_{(2,S+2)}) - I(x_S, y_S)| < \text{threshold}$ , potom  $a = a + 1$   
 $\mathbf{x}_{(a)} = x_S$ ;  $\mathbf{y}_{(a)} = y_S$   
 $\mathbf{x}_S = \mathbf{x}_S + \mathbf{D}_{(\cdot,S+2)}$   
 $SS_{(a)} = S + 2$ ;  $S = (S + 7) \bmod 8$  (skontroluj pixel 6 a choď na pixel 6)
7. if else  $|I(x_S + \mathbf{D}_{(1,S+3)}, y_S + \mathbf{D}_{(2,S+3)}) - I(x_S, y_S)| < \text{threshold}$ , potom  $a = a + 1$   
 $\mathbf{x}_{(a)} = x_S$ ;  $\mathbf{y}_{(a)} = y_S$   
 $\mathbf{x}_S = \mathbf{x}_S + \mathbf{D}_{(\cdot,S+3)}$   
 $SS_{(a)} = S + 3$ ;  $S = (S + 7) \bmod 8$  (skontroluj pixel 7 a choď na pixel 7)
8. else choď na obrisy obrazu (smer – napr. diagonálne dole vpravo,  $S = (S + 1) \bmod 8$ ; pokiaľ nenájdeš pixel s intenzitou menšou ako  $\text{threshold}$ ; t.j. prvý pixel pozadia)
9. return  $\mathbf{x} = \mathbf{y}_{(-1)}$  a  $\mathbf{y} = (\dim(I)_{(1)} - \mathbf{x})_{(-1)}$  (vymaž prvý element, ktorý je rovný poslednému – štartovací bod; pozri slajd "Digitálny obraz – definícia")

## Example 15

### Uzavreté obrisy

#### Example (pokrač. príkladu 11 a 12)

Majme lastúru (*Mitilus* sp.) uloženú ako PPM. Použite binarizovaný obraz  $M$  pri thresholde 0.9 z príkladu 11. Extrahujte súradnice obrisy lastúry.

1. Zobrazte binarizovaný obraz  $M$  (pri thresholde 0.9).
2. Pomocou funkcie `locator()` označte štartovací bod  $\mathbf{x}_S$  vnútri lastúry.
3. Na identifikáciu obrisy použite algoritmus `kontura`.
4. Resamplujte súradnice bodov obrisy na  $k = 32$ , kde body budú **ekvidišťantne vzdialené – s rovnakou uhlovou vzdialenosťou medzi nimi**, kde je potrebné vybrať  $k = 32$  ekvidišťantných bodov z 629 identifikovaných bodov s použitím funkcie `seq(1, 629, length=32)`.
5. Resamplujte súradnice bodov obrisy na  $k = 32$ , kde body budú **ekvidišťantne vzdialené – s rovnakou radiálnou vzdialenosťou medzi nimi**, kde najprv vypočítate centroid lastúry (aritmetický priemer súradníc obrisy získaných v bode (4)), potom pomocou znalostí z analýzy komplexných čísel vyberiete tie z 629 súradníc identifikovaných algoritmom `kontura`, ktoré patria prieniku kontúry a ramien uhlov  $\frac{2 \times i \times \pi}{k}$ ,  $i = 0, 1 \dots k$ , s vrcholom v bode (0, 0).

## Example 15

### Uzavreté obrisy

#### Riešenia:

```

1 plot(M, main="Binary image, threshold = 0.9")
2 x.start <- locator(1)
  x.start <- round(c(x.start$x, x.start$y))
3 myt.contour <- kontura(x.start, M@grey, start.threshold =
  0.1, threshold = 0.1) lines(myt.contour$x, myt.contour$y, lwd=3)
4 k.r=32; k <- length(myt.contour$x)
  myt.contour.x <- (myt.contour$x[seq(1, k, length=k.r)])
  myt.contour.y <- (myt.contour$y[seq(1, k, length=k.r)])
  plot(myt.contour.x, myt.contour.y, type="l", lwd=1.1,
  asp=1, axes=FALSE, main="Equidistantly spaced
  coordinates")
  points(myt.contour.x, myt.contour.y, pch=16, cex=0.7)
5 plot(myt.contour.x, myt.contour.y, type="l", lwd=1.1, asp=1, axes=FALSE,
  main="Radially spaced coordinates")
  mean.x <- mean(myt.contour$x)
  mean.y <- mean(myt.contour$y)
  points(mean.x, mean.y, pch=16)
  r.coords <- radial.coords(myt.contour$x, myt.contour$y, 32)
  points(mean.x + r.coords$coords[,1], mean.y +
  r.coords$coords[,2], pch=16, cex=0.7)
  for (i in 1:k.r) {
    segments(mean.x, mean.y,
    mean.x + r.coords$coords[,1],
    mean.y + r.coords$coords[,2])
  }

```



## Example 15

### Uzavreté obrisy

#### Riešenia (pokrač.):

```
"radial.coords" <- function(Rx, Ry, k1) {  
  k <- length(Rx)  
  M <- matrix(c(Rx, Ry), k, 2)  
  M1 <- matrix(c(Rx-mean(Rx), Ry-mean(Ry)), k, 2)  
  V1 <- complex(real = M1[,1], imaginary = M1[,2])  
  M2 <- matrix(c(Arg(V1), Mod(V1)), k, 2)  
  V2 <- NA  
  for (i in 0:(k1-1)) V2[i+1] <- which.max((cos(M2[,1] - 2*i*pi/k1)))  
  V2 <- sort(V2)  
  RES <- list("IDs" = V2, "radii" = M2[V2,2], "coords" = M1[V2,])  
  return(RES)  
}
```


## Example 15

### Uzavreté obrisy

Grey scale image




Binary image, threshold = 0.9



Equidistantly spaced coordinates



Radially spaced coordinates



**Obrázok:** Obrázok lastúry *Mytilus sp.* v sivej škále (prvý riadok vľavo), binarizovaný s extrahovaným obrysom (prvý riadok vpravo), ekvidištantné body obrysu s identickou uhlovou vzdialenosťou (druhý riadok vľavo) a s identickou radiálnou vzdialenosťou (druhý riadok vpravo)

## Example 16

### Uzavreté obrisy

#### Example (pokrač. príkladu 13)

Majme hmyzie krídlo uložené ako **JPEG**. Extrahujte súradnice obrysu krídla.

- 1 Binarizujte obraz  $M$  (pri thresholde 0.95).
- 2 Pomocou funkcie `locator()` označte štartovací bod  $x_S$  vnútri krídla.
- 3 Na identifikáciu obrysu použite algoritmus `kontura`.
- 4 Resamplujte súradnice bodov obrysu na  $k = 64$ , kde body budú **ekvidištantne vzdialené – s rovnakou uhlovou vzdialenosťou medzi nimi**.
- 5 Resamplujte súradnice bodov obrysu na  $k = 64$ , kde body budú **ekvidištantne vzdialené – s rovnakou radiálnou vzdialenosťou medzi nimi**.


## Example 16

### Uzavreté obrisy


Grey scale image, threshold = 0.95




Original image



Equidistantly spaced coordinates



Radially spaced coordinates



**Obrázok:** Obrázok hmyzieho krídla binarizovaný s extrahovaným obrysom (prvý riadok vľavo), v sivej škále s extrahovaným obrysom (prvý riadok vpravo), ekvidištantné body obrysu s identickou uhlovou vzdialenosťou (druhý riadok vľavo) a s identickou radiálnou vzdialenosťou (druhý riadok vpravo)

## Example 17

Uzavreté obrisy

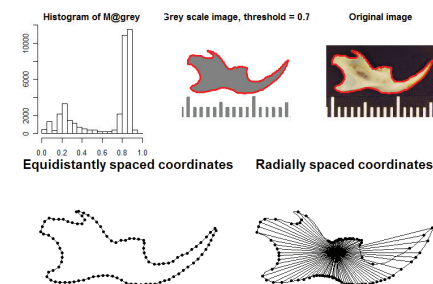
### Example (pokrač. príkladu 14)

Majme sánku uloženú ako **JPEG**. Extrahujte súradnice obrisy sánky.

- 1 Binarizujte obraz  $M$  (pri thresholde 0.7).
- 2 Pomocou funkcie `locator()` označte štartovací bod  $x_s$  vnútri sánky.
- 3 Na identifikáciu obrisy použite algoritmus kontúra.
- 4 Resamplujte súradnice bodov obrisy na  $k = 100$ , kde body budú **ekvidištantne vzdialené – s rovnakou uhlovou vzdialenosťou medzi nimi**.
- 5 Resamplujte súradnice bodov obrisy na  $k = 100$ , kde body budú **ekvidištantne vzdialené – s rovnakou radiálnou vzdialenosťou medzi nimi**.
- 6 Je možné použiť súradnice bodov ekvidištantne vzdialených (s identickou radiálnou vzdialenosťou)? Ak nie prečo?

## Example 17

Uzavreté obrisy



**Obrázok:** Histogram intenzity sivej (prvý riadok vľavo), obrázok sánky binarizovaný s extrahovaným obrysom (prvý riadok v strede), v RGB škále s extrahovaným obrysom (prvý riadok vpravo), ekvidištantné body obrisy s identickou uhlovou vzdialenosťou (druhý riadok vľavo) a s identickou radiálnou vzdialenosťou (druhý riadok vpravo)

Stanislav Katina

Štatistická analýza tvaru a obrazu

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 18

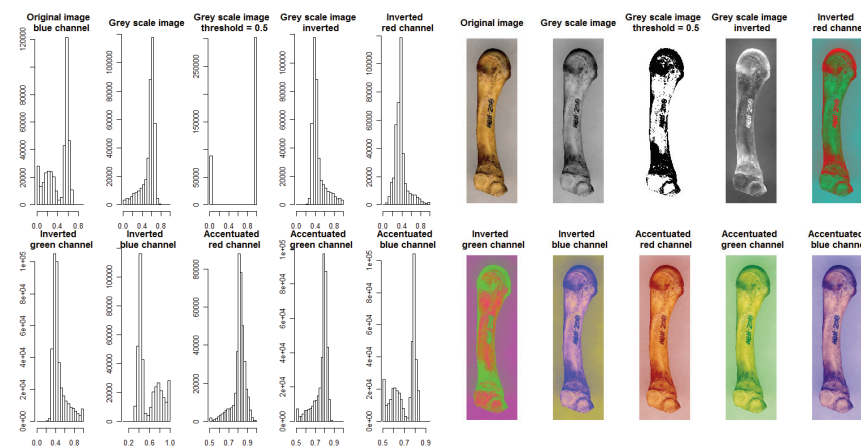
Uzavreté obrisy – zložitejšia situácia na metakarpe ľudskej ruky 1



**Obrázok:** Originálny obraz metakarpu ľudskej ruky

## Example 18

Uzavreté obrisy – zložitejšia situácia na metakarpe ľudskej ruky 2



**Obrázok:** Histogramy rôznych transformácií farebných komponentov obrazu a nim zodpovedajúce obrázky metakarpu ľudskej ruky

Stanislav Katina

Štatistická analýza tvaru a obrazu

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 18


Uzavreté obrysy – zložitejšia situácia na metakarpe ľudskej ruky 3



Obrázok: Extrahovaný obrys metakarpu ľudskej ruky

## Example 19


Uzavreté obrysy – zložitejšia situácia ľudskej ruky 1



Obrázok: Obraz ľudskej ruky

## Example 19

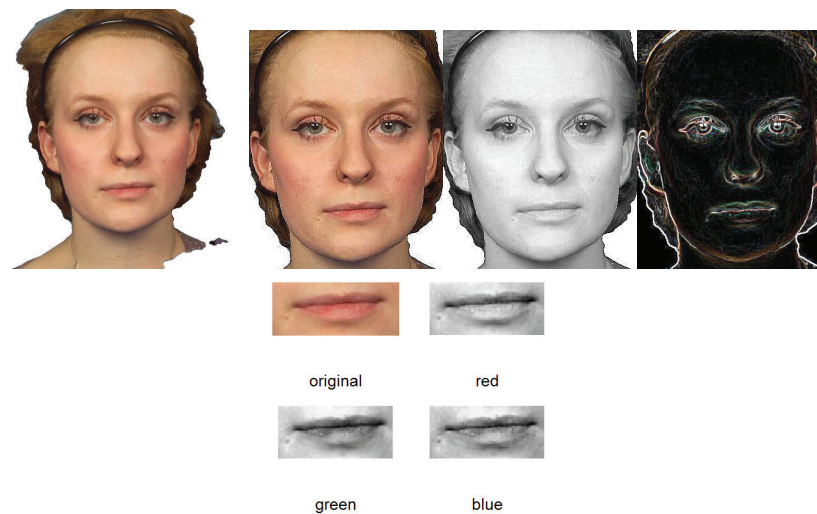
Uzavreté obrysy – zložitejšia situácia ľudskej ruky 2



Obrázok: Extrakcia obrysu ľudskej ruky

## Example 20 A – otvorený problém

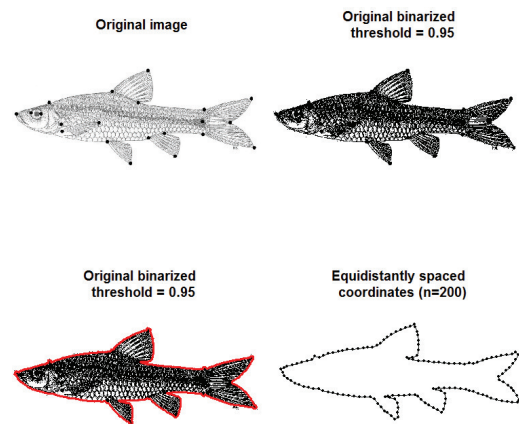
Uzavreté obrysy – (pravdepodobne) neriešiteľná situácia ľudskej tváre a pier



Obrázok: Obrazy rôznych transformácií komponentov obrazu ľudskej tváre a pier, extrahované hrany (vpravo hore)

## Example 20 B – otvorený problém

Uzavreté obrisy – stačí len extrakcie obrysu?




Obrázok: Extrakcia obrisy hrúzovca sieťovaného (*Pseudorasbora parva*)

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 20 B – otvorený problém

Uzavreté obrisy a ich vnútro – potrebná extrakcie objektu ako celku



Obrázok: Extrakcia sumčeka čierneho (*Ameiurus melas*) z pozadia

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analýza obrazu

Geometrické operácie

### Definition (Geometrické operácie)

**Geometrické operácie** transformujú obraz  $I$  do nového obrazu  $I'$  transformáciou súradníc jednotlivých pixelov,

$$I(u, v) \rightarrow I'(u', v'),$$

kde hodnoty intenzity obrazu  $I$  pôvodne v bode  $(u, v)$  sú transformované do bodu  $(u', v')$  v novom obraze  $I'$ . Transformačná funkcia má potom tvar

$$T: \mathbb{R}^2 \rightarrow \mathbb{R}^2$$

a je definovaná pre každý bod *vzorového obrazu*  $\mathbf{x} = (u, v)$  a korešpondujúci bod *transformovaného obrazu*  $\mathbf{x}' = (u', v')$ , kde  $\mathbf{x}' = T(\mathbf{x})$ .

Príklady geometrických operácií:


- 1 **afinne transformácie** – **otočenie**, **posunutie**, **škálovanie**, **skosenie** a **zrkadlenie**
- 2 **TPS modely** – **interpoláčny thin-plate splajn (TPS) model** [IM1, IM3] a **penalizovaný TPS regresný model** [PRM1, PRM3]

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 21

Geometrické operácie – **warping** ľudskej ruky 1 (pozor nie **morfing**)



Obrázok: Ľudská ruka a 16 landmarkov

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 21

Geometrické operácie – **warping** ľudskej ruky 2 (pozor nie **morfing**)




Obrázok: Dve ľudské ruky – chceme transformovať ľavú na pravú

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 21

Geometrické operácie – **warping** ľudskej ruky 3 (pozor nie **morfing**)



Obrázok: Ľudské ruky – vzorová ruka, odhadnutá ruka, affinná a neaffinná komponenta transformácie (po stĺpcoch) [approx. 1.6mil premenných]

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Example 22

Geometrické operácie – **warping** Fredovej tváre (pozor, nie **morfing**)



Obrázok: Prof. Fred Bookstein – originálna (vľavo) a transformovaná fotografia (vpravo) [s láskavým dovolením zakladateľa odboru Analýza tvaru]

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analýza tvaru

Analýza obrysov

### Definition (Obrys)

**Obrys** je **uzavretá krivka** definovaná súradnicami  $k$  bodov (semilandmarkov) patriacich tomuto obrysu, kde body sú

- 1 ekvidištantne vzdialené s rovnakou **radiálnou vzdialenosťou** medzi nimi.
- 2 ekvidištantne vzdialené s rovnakou **uhlovou vzdialenosťou** medzi nimi.

### Definition (Analýza obrysov)

Štatistická analýza obrysu závisí od toho, o aký typ obrysu ide.

- 1 Ak ide o obrys typu (1), používa sa **radiálna Fourierova analýza**.
- 2 Ak ide o obrys typu (2), používa sa **tangenciálna Fourierova analýza** alebo **eliptická Fourierova analýza**.

**2D/3D Fourierova analýza** je zovšeobecnením klasickej Fourierovej analýzy používanej v časových radoch na analýzu periodického signálu v dátach, kde sa aplikuje rozklad Fourierovho radu použitím diskretných Fourierových transformácií. Služi ja na **výraznú redukciu dimenzii**.

Stanislav Katina

Štatistická analýza tvaru a obrazu

### Definition (Klasická Fourierova analýza)

**Fourierov rozklad periodickej funkcie**  $f(t)$ , kde  $t \in \mathbb{R}^+$  s periódou  $T_\lambda = \frac{\pi}{\lambda}$  v nejakých časových jednotkách, bude mať tvar

$$f(t) = \frac{a_0}{2} + \sum_{i=1}^p (a_i \cos(\lambda_i t) + b_i \sin(\lambda_i t)), \text{ kde } \lambda_i = \frac{i}{T} 2\pi$$

je  $i$ -ta frekvencia funkcie  $f(t)$  v radiánoch  $\lambda \in (0, 2\pi)$ ,

$$a_i = \frac{2}{T} \int_{t_1}^{t_2} f(t) \cos(\lambda_i t) dt; b_i = \frac{2}{T} \int_{t_1}^{t_2} f(t) \sin(\lambda_i t) dt$$

sú **párne a nepárne Fourierove koeficienty** a  $T$  je potrebné zvoliť. Aplikácia  $f(t)$  predstavuje prepis do podoby **nelineárneho regresného modelu** tvaru

$$f(t) = a_{01} + a_{02}t + \sum_{i=1}^p (a_i \cos(\lambda_i t) + b_i \sin(\lambda_i t)) + \epsilon_t, \text{ kde } \lambda_i = i \frac{\pi}{T},$$

kde je potrebné odhadnúť  $3p + 3$  parametrov a model linearizovať.

### Definition (Radiálna Fourierova analýza, RFA)

Majme obrys centrováný do bodu  $(0, 0)$ . **Lúče (ramená)**  $r_j, j = 1, 2, \dots, k$ , **uhlov**  $\theta_j$  s vrcholom v bode  $(0, 0)$  je možné popísať **periodickou funkciou**  $r(\theta)$  nejakého uhla  $\theta$  nasledovne

$$r(\theta) = \frac{a_0}{2} + \sum_{i=1}^p (a_i \cos(\lambda_i \theta) + b_i \sin(\lambda_i \theta)), \text{ kde } \lambda_i = i.$$

Potom  $j$ -ta harmonická zložka je rovná  $r(\theta_j)$ ,  $a_0 = 2\sqrt{\sum_{j=1}^k r_j/k}$ ,

$$a_i = \frac{2}{k} \sum_{j=1}^k r_j \cos(i\theta_j); b_i = \frac{2}{k} \sum_{j=1}^k r_j \sin(i\theta_j)$$

sú **párne a nepárne Fourierove koeficienty**,  $k$  je **počet lúčov** a zároveň semilandmarkov obrysu a  $p$  je **počet frekvencií**. Musí byť splnená **podmienka**  $p < \frac{k}{2}$ , lebo máme dva parametre na jednu harmonickú zložku, ktorá je funkciou nejakého jedného uhla  $\theta$ . **Označenia:** obrys  $\mathbf{M}$  a  $\mathbf{M}_{RFA}^{(p)}$ .


### Metodologické poznámky:

- 1 všetky obrysy z náhodného výberu **musia byť automaticky extrahované pomocou reťazového kódu rovnakým smerom**
- 2 treba mať na zreteli, že **smer výpočtu lúčov v RFA je proti smeru hodinových ručičiek a odhadovanie je sekvenčné**
- 3 **štartovací bod a smer zoradenia bodov na obryse musia byť kompatibilné so štartovacím bodom a smerom odhadovania lúčov RFA**, teda proti smeru hodinových ručičiek; ak nie je, je potrebné zoradenie v smere hodinových ručičiek zmeniť na proti smeru hodinových ručičiek
- 4 **uhol a orientácia prvého ramena musí byť rovnaká** pri všetkých obrysoch z náhodného výberu – všetky obrysy je potrebné rotovať do tejto polohy, t.j. nulté rameno je na osi  $x$ -ovej, smeruje k jej kladnej polovici s vrcholom v bode  $(0, 0)$ , čo docielime centrovaním obrysu do jeho centroidu (aritmetický priemer súradníc bodov obrysu) a otočením nultého ramena do osi  $x$
- 5 ak chceme porovnávať **obrysy párového typu** (ľavá a pravá strana), je potrebné extrahovať jednu stranu proti smeru hodinových ručičiek a druhú v smere hodinových ručičiek s **opačne orientovaným nultým uhlom** a potom napr. ľavú stranu transformovať pomocou osovej súmernosti (s osou v osi  $y$ )
- 6 **minimálny počet harmonických koeficientov**  $p$  sa odhadne ako  $d_p = \arg \min_{\nu, p} \|\mathbf{M} - \mathbf{M}_{RFA}^{(p)}\|^2$
- 7 RFA **nemôže byť použitá v prípadoch, keď aspoň jedno rameno (lúč) pretne obrys viac ako jedenkrát**


### Example (pokrač. príkladu 16)

Majme hmyzie krídlo uložené ako **JPEG** a resamplované súradnice semilandmarkov obrysu pomocou radiálnych vzdialeností vypočítané v príklade 16.

- 1 Odhadnite obrys krídla pomocou RFA pri optimálnom  $p$ .



**Obrázok:** Obrys  $\mathbf{M}$  superponovaný s obrysom  $\mathbf{M}_{RFA}^{(8)}$  so segmentami spájajúcimi korešpondujúce body, rozptylový graf počtu harmonických koeficientov voči  $d_p$  (suboptimálne  $p = 8$ )



**Obrazok:** Obrys  $M$  superponovaný s obrysami  $M_{RFA}^{(\rho)}$ ,  $\rho = 1, 2, \dots, 8$

**Pozn.:** Súradnice sú vypočítané v tvare **komplexných čísel**, kde modulus =  $r(\theta_j)$ , argument =  $\theta_j$ .

## Definition (Eliptická Fourierova analýza, EFA)

Majme obrys centrováný do bodu  $(0, 0)$ . Nech  $T$  je **obvod obrysu**,  $\lambda = 2\pi/T$  je **frekvencia** a nech  $t \in \langle 0, T \rangle$  je **chordálna (uhlová) vzdialenosť**. Potom je možné pomocou  $t$  vyjadriť súradnice semilandmarkov obrysu ako  $x(t)$  a  $y(t)$  nasledovne

$$x(t) = \frac{a_0}{2} + \sum_{i=1}^{\infty} (a_i \cos(i\lambda t) + b_i \sin(i\lambda t)), \text{ kde}$$

$$a_i = \frac{2}{T} \int_0^T x(t) \cos(i\lambda t) dt; b_i = \frac{2}{T} \int_0^T x(t) \sin(i\lambda t) dt,$$

$$y(t) = \frac{c_0}{2} + \sum_{i=1}^{\infty} (c_i \cos(i\lambda t) + d_i \sin(i\lambda t)), \text{ kde}$$

$$c_i = \frac{2}{T} \int_0^T y(t) \cos(i\lambda t) dt; d_i = \frac{2}{T} \int_0^T y(t) \sin(i\lambda t) dt.$$

## Definition (EFA, pokrač.)

Ak je obrys definovaný pomocou  $k$  semilandmarkov, potom môžeme **Fourierove koeficienty** odhadnúť nasledovne

$$a_i = \frac{T}{2\pi^2 n^2} \sum_{j=1}^k \frac{\Delta x_j}{\Delta t_j} \left( \cos\left(i \frac{2\pi t_j}{T}\right) - \cos\left(i \frac{2\pi t_{j-1}}{T}\right) \right), \Delta x_1 = x_1 - x_k,$$

$$b_i = \frac{T}{2\pi^2 n^2} \sum_{j=1}^k \frac{\Delta x_j}{\Delta t_j} \left( \sin\left(i \frac{2\pi t_j}{T}\right) - \sin\left(i \frac{2\pi t_{j-1}}{T}\right) \right), a_0 = \frac{2}{T} \sum_{j=1}^p x_j,$$

$$c_i = \frac{T}{2\pi^2 n^2} \sum_{j=1}^k \frac{\Delta y_j}{\Delta t_j} \left( \cos\left(i \frac{2\pi t_j}{T}\right) - \cos\left(i \frac{2\pi t_{j-1}}{T}\right) \right), \Delta y_1 = y_1 - y_k,$$

$$d_i = \frac{T}{2\pi^2 n^2} \sum_{j=1}^k \frac{\Delta y_j}{\Delta t_j} \left( \sin\left(i \frac{2\pi t_j}{T}\right) - \sin\left(i \frac{2\pi t_{j-1}}{T}\right) \right), c_0 = \frac{2}{T} \sum_{j=1}^p y_j.$$

Vypočítané koeficienty  $a_0, a_i, b_i, c_0, c_i$  a  $d_i$  použijeme na odhad  $x(t_j)$  a  $y(t_j)$  dosadením do rovníc z predchádzajúceho slajdu, kde  $\infty$  nahradíme  $p$ .

## Metodologické poznámky:

- 1 všetky obrysy z náhodného výberu **musia byť automaticky extrahované pomocou reťazového kódu rovnakým smerom**
- 2 treba mať na zreteli, že **smer výpočtu EFA je identický so smerom zoradenia bodov obrysu, odhadovanie je sekvenčné a obe metódy majú rovnaký štartovací bod**
- 3 ak chceme porovnávať **obrysy párového typu** (ľavá a pravá strana), je potrebné extrahovať jednu stranu proti smeru hodinových ručičiek a druhú v smere hodinových ručičiek s opačne orientovanou hlavnou osou a potom napr. ľavú stranu transformovať pomocou osovej súmernosti (s osou v osi  $y$ )
- 4 **minimálny počet eliptických koeficientov  $p$  sa odhadne ako**  

$$d_p = \arg \min_{\nu p} \left\| M - M_{RFA}^{(p)} \right\|^2$$
- 5 parametrická forma EFA umožňuje **jednoduché rozšírenie do 3D** pridaním  $z(t)$
- 6 **väčšie eliptické koeficienty korešpondujú s väčšími elipsami, kde obrys vzniká kombináciou superponovaných elíps**
- 7 počet eliptických koeficientov môžeme odhadnúť pomocou **Furierovej sily** definovanej ako  $Power_i = (a_i^2 + b_i^2 + c_i^2 + d_i^2)/2$ , ktorá je proporcionálna amplitúde koeficientov a **kumulatívnej Furierovej sily**  $\text{cumsum}(Power_i)$
- 8 najviac informácií o tvare obrysu je obsiahnutých v prvej elipse, pretože ide o najlepšiu aproximáciu obrysu

## Definition (NEFA – normalizácia (štandardizácia) obrysu)

**Normalizovaná eliptická Fourierova analýza (NEFA)** je EFA invariantná na veľkosť a rotáciu **prvej elipsy** a štartovací bod, kde sú koeficienty  $a_i, b_i, c_i, d_i$  transformované na  $a'_i, b'_i, c'_i, d'_i$  použitím nasledovného algoritmu

$$\begin{pmatrix} a'_i & b'_i \\ c'_i & d'_i \end{pmatrix} = \frac{1}{s_e} \begin{pmatrix} \cos \psi & \sin \psi \\ -\sin \psi & \cos \psi \end{pmatrix} \begin{pmatrix} a_i & b_i \\ c_i & d_i \end{pmatrix} \begin{pmatrix} \cos i\theta & -\sin i\theta \\ \sin i\theta & \cos i\theta \end{pmatrix},$$

kde  $s_e$  je **dĺžka hlavnej poloosi prvej elipsy**,  $\psi$  súvisí s **orientáciou elipsy** a  $\theta$  s **rotáciou štartovacieho bodu** na koniec elipsy. Potom

$$\psi = 0.5 \arctan \frac{2(a_1 b_1 - c_1 d_1)}{a_1^2 + c_1^2 - b_1^2 - d_1^2}, s_e = \sqrt{a_*^2 + c_*^2}, \theta = \arctan \frac{c_*}{a_*},$$

kde  $a_* = a_1 \cos \psi + b_1 \sin \psi$  a  $c_* = c_1 \cos \psi + d_1 \sin \psi$ . Koeficienty prvej eliptickej zložky  $a'_1 = 1, b'_1 = c'_1 = 0$ . Zostávajúci koeficient  $d'_1$  súvisí s **eliptickou**


**excentricitou**, t.j. **šírko-dĺžkovým pomerom obrysu**.

Ak máme k dispozícii aj **súradnice landmarkov** na obryse, môžeme použiť na normalizáciu **GPA**.


## Example (pokrač. príkladu 16 a 23)

Majme hmyzie krídlo uložené ako **JPEG** a resamplované súradnice semilandmarkov obrysu pomocou uhlových vzdialeností vypočítané v príklade 16.

- 1 Odhadnite obrys krídla pomocou EFA pri optimálnom  $p$ .



**Obrázok:** Obrys  $M$  superponovaný s obrysom  $M_{EFA}^{(11)}$  so segmentami spájajúcimi korešpondujúce body, rozptylový graf počtu harmonických koeficientov voči  $d_p$  (suboptimálne  $p = 11$ )



**Obrázok:** Obrys  $M$  superponovaný s obrysami  $M_{EFA}^{(p)}, p = 1, 2, \dots, 12$

## Definition (Tangenciálna Fourierova analýza, TFA)

Majme obrys centrováný do bodu  $(0, 0)$ . Semilandmarky obrysu sú ekvidistantne vzdialené s rovnakou uhlovou vzdialenosťou medzi nimi. Nech  $T$  je **obvod obrysu**, ktorý je pre jednoduchosť potrebné škálovať na  $2\pi$ . Potom je možné popísať **kumulatívnu zmenu uhla dotykového vektora**  $\phi(t)$  v jednotlivých bodoch obrysu ako funkciu (kumulatívnej) chordálnej (uhlovej) vzdialenosti  $t$  ako  $\phi(t) = \theta(t) - \theta(0) - t$ , kde  $\theta(t)$  je **uhol dotykového vektora** vo vzdialenosti  $t$ ,  $\theta(0)$  je uhol dotykového vektora štartovacieho bodu a jeho odpočítanie slúži na štandardizáciu. Potom platí

$$\phi(\theta) = \frac{a_0}{2} + \sum_{i=1}^p (a_i \cos(i\theta) + b_i \sin(i\theta)), \text{ kde}$$

$$a_i = \frac{2}{k} \sum_{j=1}^k \phi(t) \cos(i\theta_j); b_i = \frac{2}{k} \sum_{j=1}^k \phi(t) \sin(i\theta_j); a_0 = 2 \sum_{j=1}^k \phi(t) / k.$$

**Pozn.:** Tak ako aj pri RFA – používame na výpočet **komplexné číslo**, v tomto prípade dostaneme  $Z$ , kde **modulus** =  $2\pi/k$ , **argument** =  $\theta(t) = \phi(t) + \theta(0) + t$ , výsledné súradnice obrysu sú **cumsum(Z)**, kt. musíme centrovať do  $(0, 0)$ .



# Example 25


TFA 2

## Example (pokrač. príkladu 16, 23 a 24)

Majme hmyzie krídlo uložené ako **JPEG** a resamplované súradnice semilandmarkov obrysu pomocou uhlových vzdialeností vypočítané v príklade 16.

1 Odhadnite obrys krídla pomocou TFA pri optimálnom  $p$ .

Pozn.: Najjednoduchší spôsob aproximácie uhla dotykového vektora je pomocou rozdielu dvoch susediacich bodov obrysu. Treba si uvedomiť, že vplyv uhla  $\theta(0)$  môže mať výrazný efekt na odhad obrysu.



Obrázok: Obrys  $M$  superponovaný s obrysom  $M_{TFA}^{(20)}$  so segmentami spájajúcimi korešpondujúce body (bez a s odpočítaním  $\theta(0)$ )

Stanislav Katina

Statistická analýza tvaru a obrazu

# Example 25

TFA 3



$d(p) = 25.269$

$d(p) = 3.702$

$d(p) = 2.638$

$d(p) = 2.352$




$d(p) = 4.928$

$d(p) = 3.877$

$d(p) = 2.368$

$d(p) = 2.406$



$d(p) = 5.414$

$d(p) = 2.397$

$d(p) = 2.502$

$d(p) = 2.318$

Obrázok: Obrys  $M$  superponovaný s obrysami  $M_{TFA}^{(p)}$ ,  $p = 1, 2, \dots, 12$

Stanislav Katina

Statistická analýza tvaru a obrazu

# Analýza tvaru

Analýza kriviek (sliding on curves) – geometrická homológia

## Definition (Matica ohybovej energie a ohybová energia)

Majme **TPS** model [IM3] definovaný ako

$$\begin{pmatrix} \mathbf{Y} \\ \mathbf{0} \\ \mathbf{0} \end{pmatrix} = \begin{pmatrix} \mathbf{S} & \mathbf{1}_k & \mathbf{X} \\ \mathbf{1}_k^T & \mathbf{0} & \mathbf{0} \\ \mathbf{X}^T & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{W} \\ \mathbf{c}^T \\ \mathbf{A} \end{pmatrix}, \mathbf{L} = \begin{pmatrix} \mathbf{S} & \mathbf{1}_k & \mathbf{X} \\ \mathbf{1}_k^T & \mathbf{0} & \mathbf{0} \\ \mathbf{X}^T & \mathbf{0} & \mathbf{0} \end{pmatrix},$$

Nech je inverzia matice  $\mathbf{L}$  rovná

$$\mathbf{L}^{-1} = \begin{pmatrix} \mathbf{L}_{k \times k}^{11} & \mathbf{L}_{k \times 3}^{12} \\ \mathbf{L}_{3 \times k}^{21} & \mathbf{L}_{3 \times 3}^{22} \end{pmatrix},$$

potom

1 matica ohybovej energie:  $\mathbf{B}_e = \mathbf{L}_{k \times k}^{11}$

2 ohybová energia alebo penalta:

$$J(\mathbf{f}) = \sum_{m=1}^2 \int \int_{\mathbb{R}^2} \left[ \sum_{i,j} \left( \frac{\partial^2 f_m}{\partial x^{(i)} \partial x^{(j)}} \right)^2 \right] dx^{(1)} dx^{(2)}, \text{ s riešením modelu IM3}$$



$$J(\mathbf{f}) = \text{tr}(\mathbf{W}^T \mathbf{S} \mathbf{W}) = \text{tr}(\mathbf{Y}^T \mathbf{B}_e \mathbf{Y})$$

Stanislav Katina

Statistická analýza tvaru a obrazu

# Analýza tvaru

Analýza kriviek (sliding on curves) – geometrická homológia



Obrázok: **Cirkularita ohybovej energie** vo vzťahu ku polohe piateho landmarku v prostredku štvorca

Stanislav Katina

Statistická analýza tvaru a obrazu

## Analyza tvaru

Analyza kriviek (sliding on curves) – geometrická homológia

Definition (Analyza kriviek – posuvanie semilandmarkov po krivke)

Nech  $\mathbf{X}_{k \times 2} = (\mathbf{x}_1, \dots, \mathbf{x}_k)^T = (\mathbf{x}^{(1)}, \mathbf{x}^{(2)})$  a  $\mathbf{Y}_{k \times 2} = (\mathbf{y}_1, \dots, \mathbf{y}_k)^T = (\mathbf{y}^{(1)}, \mathbf{y}^{(2)})$  sú konfiguračné matice s riadkami  $\mathbf{x}_j = (x_j^{(1)}, x_j^{(2)})^T$  a  $\mathbf{y}_j = (y_j^{(1)}, y_j^{(2)})^T$ , kde  $\mathbf{x}^{(m)} = (x_1^{(m)}, x_2^{(m)}, \dots, x_k^{(m)})^T$ ,  $\mathbf{y}^{(m)} = (y_1^{(m)}, y_2^{(m)}, \dots, y_k^{(m)})^T$ ,  $j = 1, 2, \dots, k$  a  $m = 1, 2$ . Nech body sublistu  $\mathbf{y}_{j_i}$  **posúvame mimo ich pôvodnej polohy**  $\mathbf{x}_{j_i}$ ,  $i = 1, 2, \dots, q \leq k$ , **pozdĺž tangenciálneho smeru**  $\mathbf{u}_i = (u_i^{(1)}, u_i^{(2)})^T$ , kde  $\|\mathbf{u}\|_2 = 1$ . Potom nová poloha  $\mathbf{x}_{j_i}$  je definovaná ako

$$\mathbf{y}_{j_i} = \mathbf{x}_{j_i} + t_i \mathbf{u}_i, i = 1, 2, \dots, q \leq k, \text{ kde } \mathbf{u}_i = \frac{\mathbf{x}_{i+1} - \mathbf{x}_{i-1}}{\|\mathbf{x}_{i+1} - \mathbf{x}_{i-1}\|_2} \text{ a } \mathbf{t} = (t_1, \dots, t_q)^T.$$

Je potrebné **minimalizovať kvadratickú formu**

$$\mathbf{y}^T \mathbf{B} \mathbf{y} = (\mathbf{x} + \mathbf{U} \mathbf{t})^T \mathbf{B} (\mathbf{x} + \mathbf{U} \mathbf{t}),$$

kde  $\mathbf{x} = \text{Vec}(\mathbf{X})$  a  $\mathbf{y} = \text{Vec}(\mathbf{Y})$ ,  $\mathbf{B} = \text{diag}(\mathbf{B}_e, \mathbf{B}_e)$ ,  $\mathbf{B}_e$  je závislá iba na nejakej (referenčnej) konfiguračnej matici  $\mathbf{X}^*$ .

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analyza tvaru

Analyza kriviek (sliding on curves) – geometrická homológia

Definition (Analyza kriviek – posuvanie semilandmarkov po krivke; pokrač.)

Kvadratickú formu  $\mathbf{y}^T \mathbf{B} \mathbf{y}$  minimalizujeme cez **hyperrovinu**

$$\mathbf{y} = \mathbf{x} + \mathbf{U} \mathbf{t},$$

kde  $\mathbf{X}$  je matica landmarkov vzoru (pôvodná poloha) a  $\mathbf{Y}$  je matica landmarkov obrazu (nová poloha),  $\mathbf{U}$  je matica riadkov dĺžky  $2k$  a stĺpcov dĺžky  $q$ , kde  $(j, i)$ -ty element označujeme  $u_i^{(j)}$  a  $(k + j, i)$ -ty element  $u_i^{(j)}$ , na iných miestach sú umiestnené nuly. Vektor  $\mathbf{t}$  je riešením nasledujúcej rovnosti

$$\begin{aligned} \frac{\partial}{\partial \mathbf{t}} (\mathbf{x} + \mathbf{U} \mathbf{t})^T \mathbf{B} (\mathbf{x} + \mathbf{U} \mathbf{t}) &= \frac{\partial}{\partial \mathbf{t}} (\mathbf{x}^T \mathbf{B} \mathbf{x} + \mathbf{x}^T \mathbf{B} (\mathbf{U} \mathbf{t}) + (\mathbf{U} \mathbf{t})^T \mathbf{B} \mathbf{x} + (\mathbf{U} \mathbf{t})^T \mathbf{B} (\mathbf{U} \mathbf{t})) \\ &= \mathbf{x}^T \mathbf{B} \mathbf{U} + \mathbf{U}^T \mathbf{B} \mathbf{x} + 2 \mathbf{U}^T \mathbf{B} (\mathbf{U} \mathbf{t}) \\ &= 2(\mathbf{x}^T \mathbf{B} \mathbf{U} + \mathbf{U}^T \mathbf{B} (\mathbf{U} \mathbf{t})) = 0 \end{aligned}$$

Riešenie (podobné zovšeobecnenej MNS) má tvar


$$\mathbf{t} = -(\mathbf{U}^T \mathbf{B} \mathbf{U})^{-1} \mathbf{U}^T \mathbf{B} \mathbf{x}.$$

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analyza tvaru

Analyza kriviek (sliding on curves) – geometrická homológia



Obrázok: Posuvanie bodov na krivke pri troch situáciách a dvoch tvaroch

Stanislav Katina


Štatistická analýza tvaru a obrazu

## Analyza tvaru

Analyza kriviek (sliding on curves) – geometrická homológia

Example (Symphyseálna krivka, pokrač.)

Majme symphyseálnu krivku z príkladu 3, kde  $k = 21$ , dáta (symphysis). Na **optimalizáciu polohy semilandmarkov na krivke v zmysle ohybovej energie (geometrická homológia)** použijeme konfiguračnú maticu  $\mathbf{X}$  a referenčnú (napr. priemernú) krivku  $\mathbf{X}_R$  (voči ktorej prebieha optimalizácia).




Obrázok: Posuvanie bodov na krivke pri troch situáciách – rôzne chápanie krivky (uzavretá vs otvorená), koncové body fixované vs voľné na posuvanie [dotyčnice v smere  $\mathbf{u}_i$ ,  $i = 1, 2, \dots, k$ ; ozn. • pôvodné pozície  $\mathbf{x}_i$ ]

Stanislav Katina

Štatistická analýza tvaru a obrazu

## Analýza tvaru

Analýza kriviek (sliding on curves) – geometrická homológia



**Obrázok:** Posúvanie bodov na krivke pri troch situáciách – rôzne chápanie krivky (uzavretá vs otvorená), koncové body fixované vs voľné na posúvanie [dotyčnice v smere  $\mathbf{u}_i$  s riešeniami  $\mathbf{y}_i = \mathbf{x}_i + t_i \mathbf{u}_i, i = 1, 2, \dots, q$ , ozn.  $\bullet$  pôvodné pozície  $\mathbf{x}_i$ ,  $\bullet$  odhadnuté pozície  $\mathbf{y}_i$ ]


Stanislav Katina

Statistická analýza tvaru a obrazu

## 2D tvár – snímok z klasického fotoaparátu

Dpt. of Anthropology, University of Vienna, Vienna, Austria

20 dievčat, 19 – 31ročných, 46 + 26 (semi)landmarkov





**Obrázok:** (Semi)landmarky na ľudskej tvári a **pravo-ľavá (ne)kompatibilita kódovania semilandmarkov na krivkách** [podmnožina (semi)landmarkov]

Stanislav Katina

Statistická analýza tvaru a obrazu

## 2D tvár – snímok z klasického fotoaparátu

Dpt. of Anthropology, University of Vienna, Vienna, Austria




**Obrázok:** Reliabilita náklonu hlavy pri snímaní v rôznych uhloch [podmnožina (semi)landmarkov] a jej PCA

Stanislav Katina

Statistická analýza tvaru a obrazu

## 2D tvár – snímok z klasického fotoaparátu

Dpt. of Anthropology, University of Vienna, Vienna, Austria



**Obrázok:** PCA reliability náklonu hlavy pri snímaní v rôznych uhloch [podmnožina (semi)landmarkov]


Stanislav Katina

Statistická analýza tvaru a obrazu

## 2D tvár

Získavanie dát a ich úprava v PC

### Získavanie dát a ich úprava v PC:

- 1 **nasnímanie dát klasickým fotoaparátom** – protokol snímania (dotazník, kalibrácia snímacieho systému, participanti a časový harmonogram)
- 2 **extrakcia 2D súradníc a RGB farieb** – z .jpeg a .tiff súborov a pod. do .dmp súborov čitateľných v 
- 3 **validačná štúdia (štúdia reliability)** – vhodná/optimálna orientácia tváre v anatomickom súradnicovom systéme, opakovateľnosť presnosti snímania/merania (Technical Measurement Error, TEM), lineárny regresný model so zmiešanými efektami
- 4 **(polo)automatické meranie/extrakcia súradníc (semi)landmarkov, kriviek**  $[(46 + 26) \times 2$  (semi)landmarkov]
- 5 iteratívny výpočet **súradníc geometricky homologických semilandmarkov na krivkách** použitím **TPS warpingu**  $[(46 + 26) \times 2$  (semi)landmarkov a viac ako 2mil pixelov]
- 6 **výpočet symetrizovaného priemerného tvaru (template)** (semi)landmarky na referenčnej tvári a preznačenej a zrkadlovo súmernej tvári musia byť spriemerované

Stanislav Katina

Statistická analýza tvaru a obrazu

## 3D tvár – snímok zo stereo-kamerového systému

Dental clinic, The University of Glasgow, UK; Face 3D data




Stanislav Katina

Statistická analýza tvaru a obrazu

## 3D tvár – snímok z laserového skaneru

Royal College of Surgeons in Ireland, Dublin; Face 3D data

42 párov naskenovaných tvárí, 23 landmarkov, 1664 geometricky homologických semilandmarkov na krivkách a ploche, 59242 bodov plochy trinagulovaných použitím 117386 trojuholníkov



Obrázok: VCFS tvár, laserový skaner a (ne)triangulované semilandmarky na ploche


Stanislav Katina

Statistická analýza tvaru a obrazu

## 3D tvár

Získavanie dát a ich úprava v PC

### Získavanie dát a ich úprava v PC:

- 1 **nasnímanie dát stereo-kamerovým systémom alebo laserovým skanerom** – protokol snímania (dotazník, kalibrácia snímacieho systému, participanti a časový harmonogram)
- 2 **extrakcia 3D súradníc, normál bodov na ploche, trinagulácie a RGB farieb** – z .obj, .wrl a .jpeg súborov do .dmp súborov čitateľných v 
- 3 **validačná štúdia (štúdia reliability)** – vhodná/optimálna orientácia tváre v anatomickom súradnicovom systéme, opakovateľnosť presnosti snímania/merania (Technical Measurement Error, TEM), lineárny regresný model so zmiešanými efektami
- 4 **(polo)automatické meranie/extrakcia súradníc (semi)landmarkov, kriviek a plôch**  $[1664 \times 3 = 4992, 4992 \times 42 = 209664$  bodov]
- 5 iteratívny výpočet **súradníc geometricky homologických semilandmarkov na krivkách/plochách a bodov na ploche** použitím **TPS warpingu**  $[59242 \times 3 = 177726; 177726 \times 42 = 7464492]$
- 6 **výpočet symetrizovaného priemerného tvaru (template)** (semi)landmarky na referenčnej tvári a preznačenej a zrkadlovo súmernej tvári musia byť spriemerované; plocha tiež symetrizovaná

Stanislav Katina

Statistická analýza tvaru a obrazu

