

Principal Component Analysis

Andrej Lúčný

Katedra aplikovanej informatiky FMFI UK

lucny@fmph.uniba.sk

<http://www.fmph.uniba.sk/~lucny>

Vektor

- stĺpcový $X = \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix}$
- riadkový $X = [X_1, X_2, \dots, X_n]$
- transpozícia

```
octave> A = [ 1; 2 ; 3; 4; 5]
```

```
A =
```

```
1  
2  
3  
4  
5
```

```
octave> B = [ 1 2 3 4 5 ]
```

```
B =
```

```
1 2 3 4 5
```

```
octave> A'
```

```
ans =
```


```
1 2 3 4 5
```

```
octave> B * B'
```

```
octave> B' * B
```

Báza


- Každý vektor alebo bod je vyjadrený na základe určitej bázy, ako súčet násobkov (lineárna kombinácia) bázových vektorov
- Normálne používame ako bázu jednotkové vektory



```
octave> C = [1 0].* 3 + [0 1].* 2
C =
  3  2
```

Báza

- Môžeme však použiť aj inú bázu



```
octave> D = [ 2 2 ] .* 1.5 + [ 0 1 ] .* -1
D =
    3    2
```

Napr. $[1.5, -1]$ v báze $[2, 2]$ $[0, 1]$ je to isté
ako $[3, 2]$ v báze $[1, 0]$ $[0, 1]$

Zmena bázy

- matica prechodu:
obrazy jednotkových vektorov
(zobrazenie na vhodné lineárne kombinácie)

$$(x_1, x_2) * \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} = (x'_1, x'_2)$$

znamená, že

$$\begin{aligned} x'_1 &= a_{11}x_1 + a_{21}x_2 \\ x'_2 &= a_{12}x_1 + a_{22}x_2 \end{aligned}$$

$[x_1, x_2]$ v báze $[a_{11}, a_{12}] [a_{21}, a_{22}]$ je to isté ako
 $[x'_1, x'_2]$ v báze $[1, 0] [0, 1]$

Zmena bázy

- matica prechodu:
obrazy jednotkových vektorov
(zobrazenie na vhodné lineárne
kombinácie)
príklad:

$$(1.5, -1) * \begin{pmatrix} 2 & 2 \\ 0 & 1 \end{pmatrix} = (3, 2)$$

$$\text{alt.:} \begin{pmatrix} 2 & 0 \\ 2 & 1 \end{pmatrix} * \begin{pmatrix} 1.5 \\ -1 \end{pmatrix} = \begin{pmatrix} 3 \\ 2 \end{pmatrix}$$

Napr. $[1.5, -1]$ v báze $[2, 2] [0, 1]$ je to isté
ako $[3, 2]$ v báze $[1, 0] [0, 1]$

```
octave> A=[2 2; 0 1]
```

```
A =
```

```
 2  2  
 0  1
```

```
octave> B=[1.5 -1]
```

```
B =
```

```
 1.5000 -1.0000
```

```
octave> C = B*A
```

```
C =
```

```
 3  2
```

```
octave> C = A' * B'
```

```
C =
```

```
 3  
 2
```

Inverzná matica

- K regulárnej matici (pri prechode neznižuje dimenziu = obrazy jednotkových vektorov nie sú lineárne závislé), existuje inverzná

```
octave> C*inv(A)
ans =

    1.5000 -1.0000

octave> inv(A)*A
ans =

    1  0
    0  1
```

$$A A^{-1} = I$$

Vlastné vektory a hodnoty


- uvažujme zmenu bázy, ktorá zachováva dimenziu


```
octave> P=[]
P = [](0x0)
octave> for i=-2:2
> for j=-2:2
> P=[P; i j];
> end
> end
octave> P
P=
-2 -2
-2 -1
-2 0
...
2 0
2 1
2 2

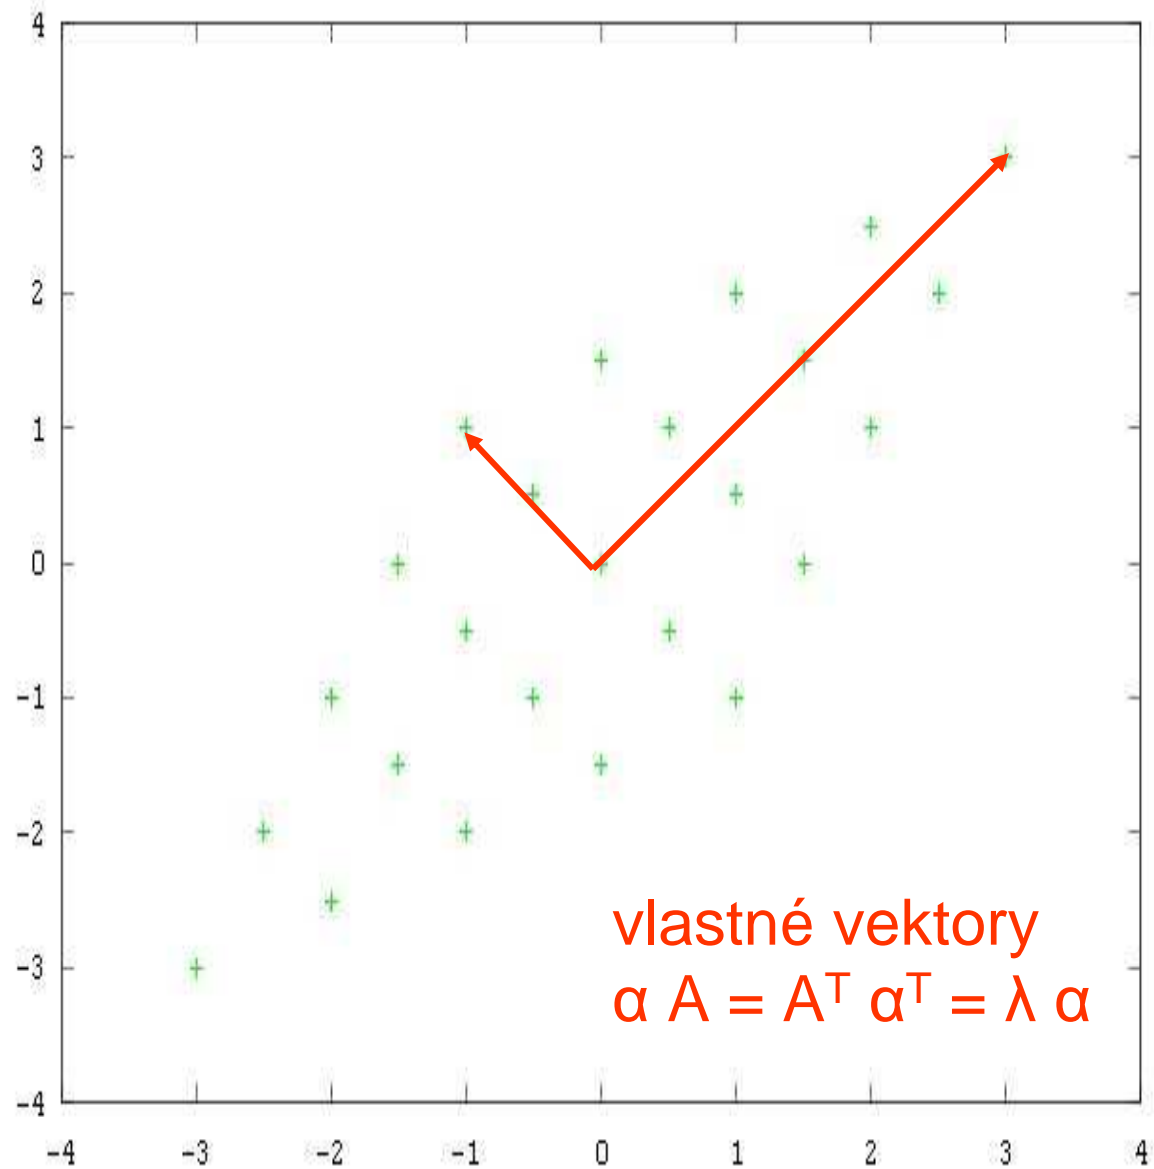
octave> plot(P(:,1),P(:,2),'g+');
octave> axis([-4 4 -4 4]);
octave> A=[1 0.5; 0.5 1]
A =

1.00000 0.50000
0.50000 1.00000

octave> Q=P*A
octave> plot(Q(:,1),Q(:,2),'g+');
```

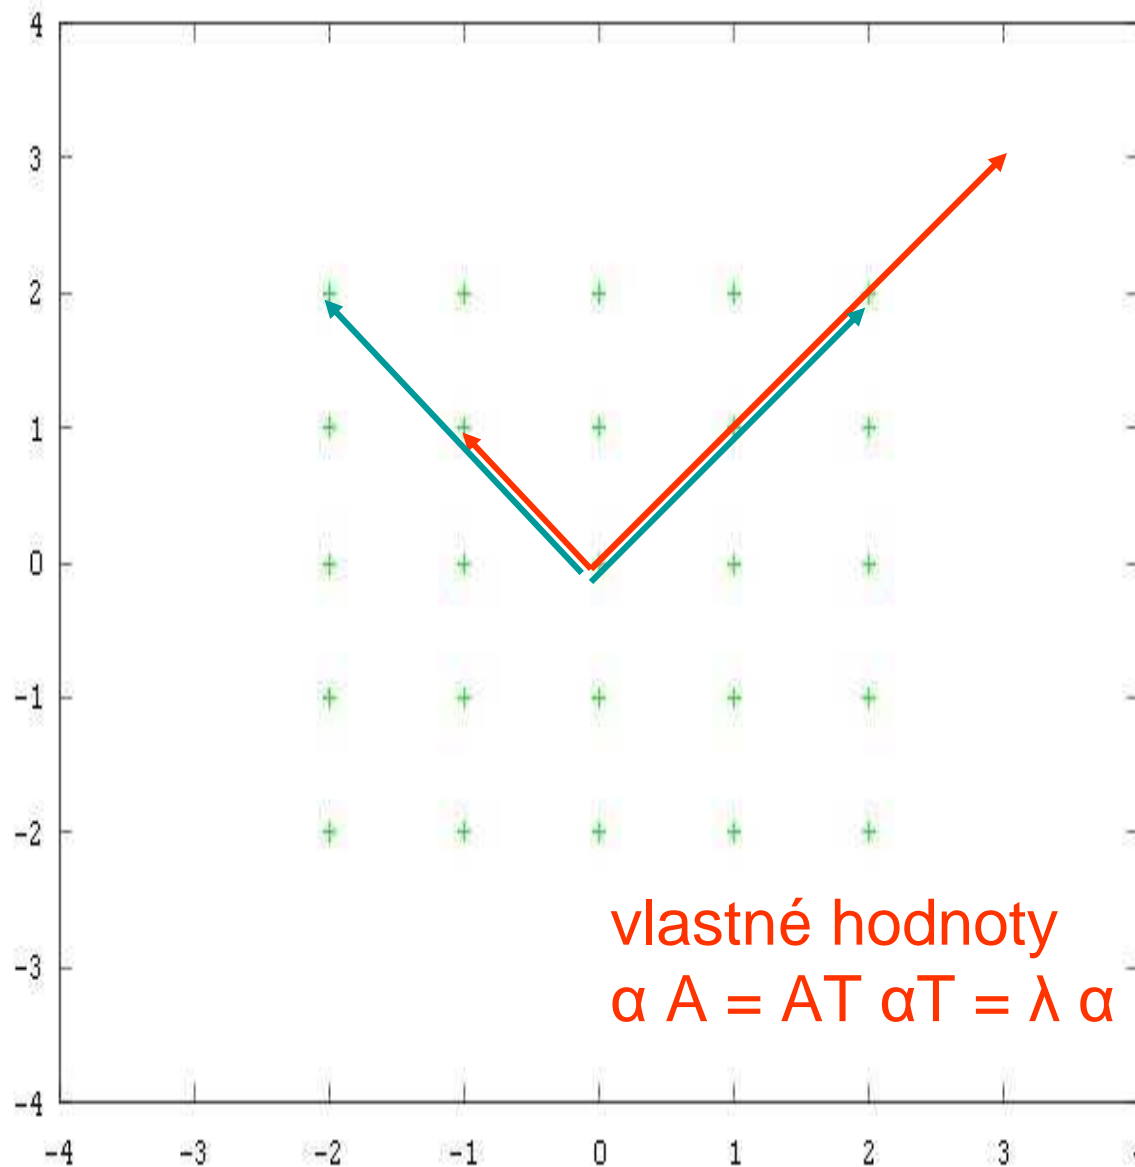







vlastné vektory udávajú v akých smeroch sa vzor deformuje na obraz

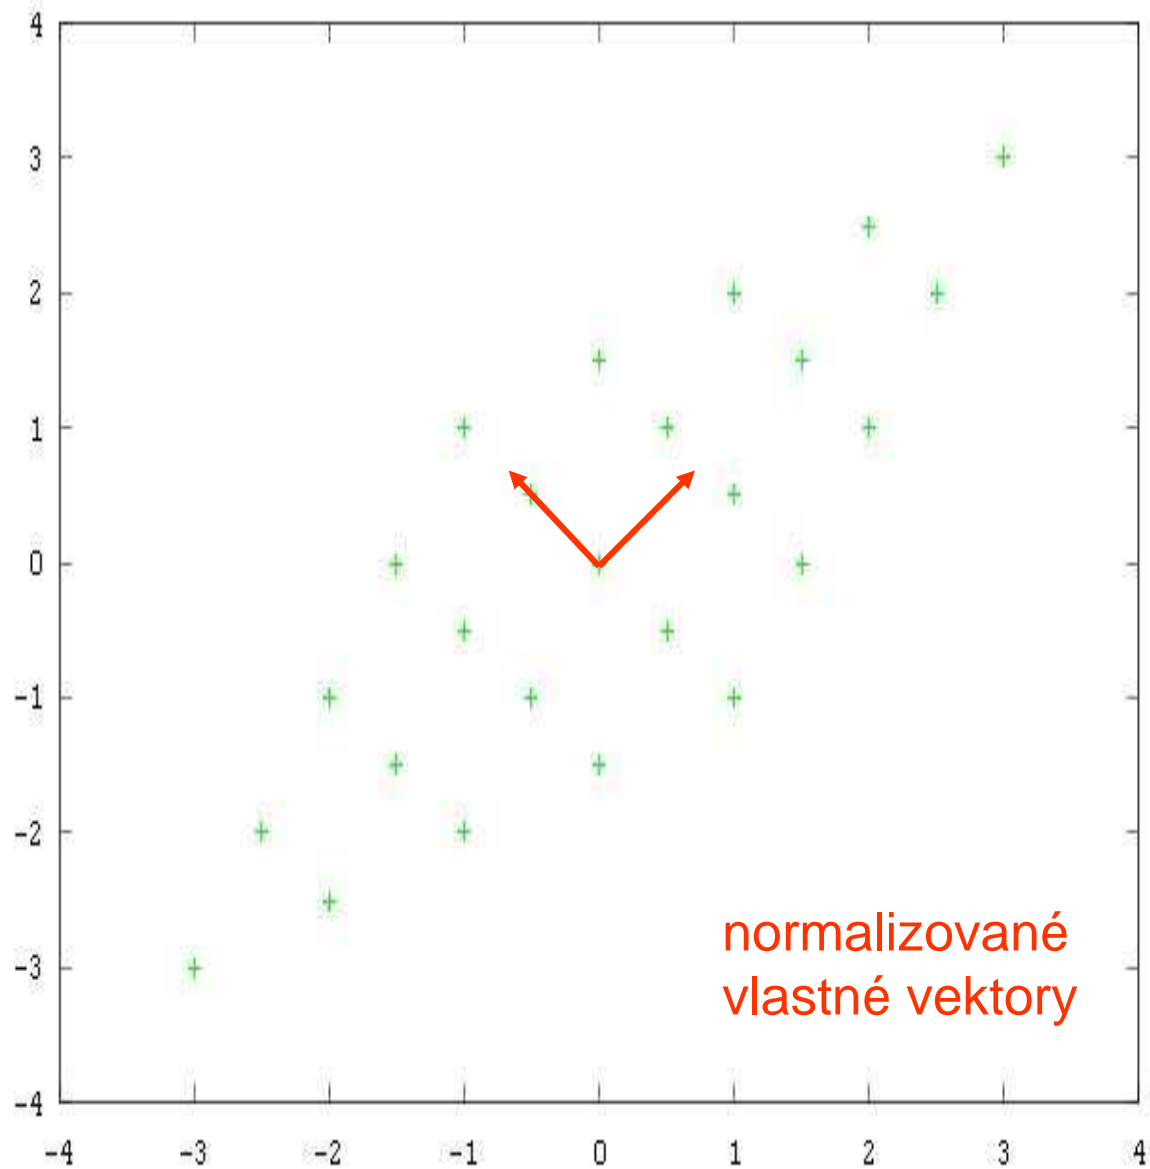
$$\frac{|\leftarrow|}{|\leftarrow|} = 1/2$$



$$\frac{|\leftarrow|}{|\leftarrow|} = 3/2$$

vlastné hodnoty udávajú zväčšovanie či zmenšovanie v deformačných smeroch

$$|\leftarrow| = 1$$



každý násobek vlastního vektoru je rovnako vhodný ale iba jeden má dĺžku 1

Vlastné vektory a hodnoty

- Existuje efektívny spôsob ako vypočítať vlastné vektory a matice
- Najprv sa spočítajú vlastné hodnoty
- Podľa každej jednej z nich (niekedy môžu byť niektoré viacnásobné – ako napr. pri identite) príslušné vlastné vektory

```
octave> [V,L] = eig(A)
V =
-0.70711  0.70711
 0.70711  0.70711
L =
0.50000  0.00000
0.00000  1.50000

octave> V(:,1)'
ans =
-0.70711  0.70711

octave> V(:,1)*A/L(1,1)
ans =
-0.70711  0.70711

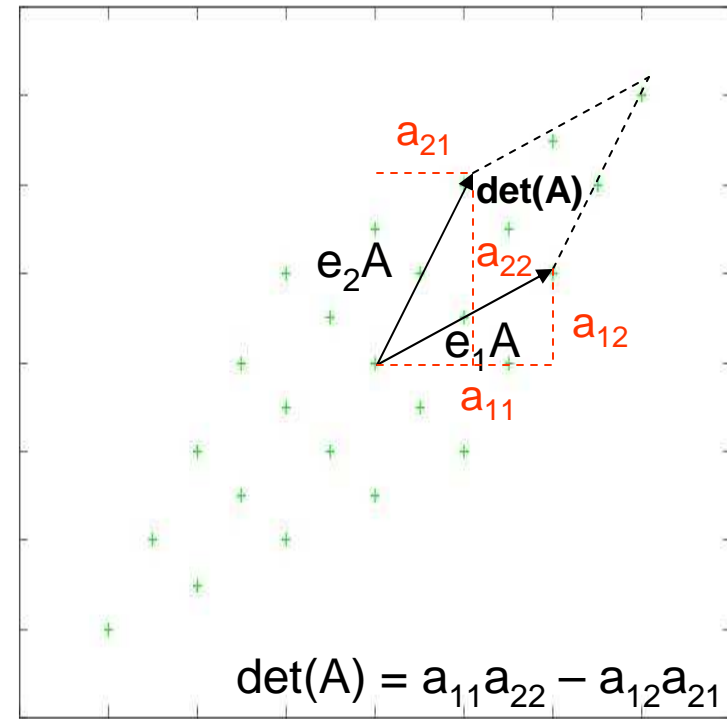
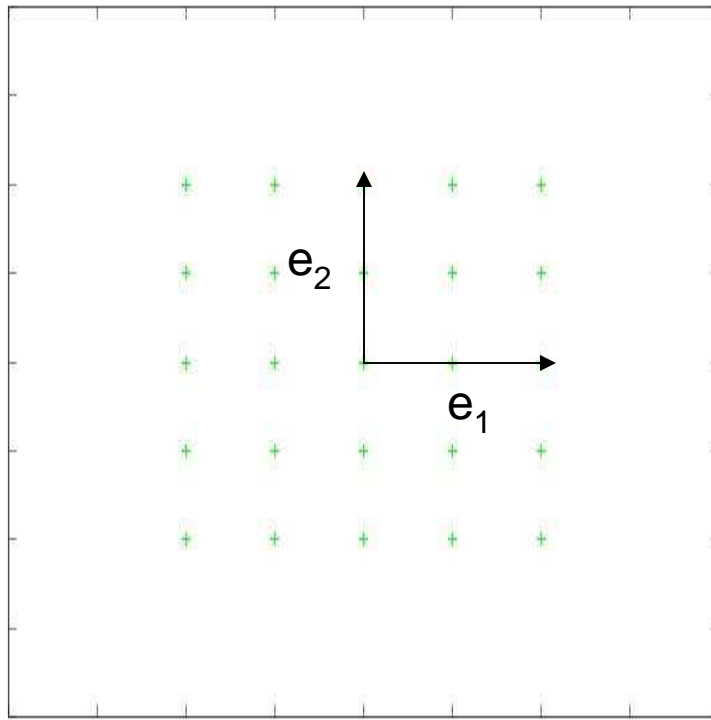
octave> V(:,2)'
ans =
 0.70711  0.70711

octave> V(:,2)*A/L(2,2)
ans =
 0.70711  0.70711

octave> [-1 1]*A/L(1,1)
ans =
-1  1
```

Len pre záujemcov

- Výpočet vlastných hodnôt sa opiera o pojem determinantu matice, čo je plocha (objem a ďalšie ich analógie v n dimenziách), ktorú zvierajú obrazy jednotkových vektorov



Len pre záujemcov

- determinant možno spočítať:

$$\det(A) = \sum_{\sigma \in S_n} \text{sgn}(\sigma) \prod_{i=1}^n A_{i,\sigma(i)} \quad \text{kde } S_n \text{ sú permutácie } n \text{ prvkov}$$

- napr. pre $A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$ je $\det(A) = a_{11}a_{22} - a_{12}a_{21}$
- determinant možno spočítať efektívne (Laplaceov rozvoj)
- determinant je nulový ak sú obrazy jednotkových vektorov lineárne závislé a teda matica pri zobrazení znižuje dimenziu

```
octave> A
A =
  1.0000  0.5000
  0.5000  1.0000
octave> B = [1 1; 2 2]
B =
  1  1
  2  2
```

```
octave> T=P*A
octave> plot(T(:,1),T(:,2),'v+');

octave> T=P*B
octave> plot(T(:,1),T(:,2),'v+');
```

```
octave> det(A)
ans = 0.75000

octave> det(B)
ans = 0
```


Len pre záujemcov

- Vlastné hodnoty potom počítame na základe úvahy:
ak $\alpha A = \lambda \alpha$ je práve vtedy keď $\alpha (A - \lambda I) = \bar{0}$
takže $(A - \lambda I)$ nesmie byť regulárna (inak $\alpha = \bar{0}$)
takže $\det(A - \lambda I) = \bar{0}$
tento determinant je polynóm premennej λ stupňa
rozmeru A
v komplexných číslach má teda toľko koreňov koľko je
rozmer A a to sú vlastné hodnoty
- Vlastné vektory potom spočítame dosadením
jednotlivých vlastných hodnôt λ do $(A - \lambda I)$ čo už je
konkrétna matica a hľadáme riešenia sústavy lineárnych
rovníc $(A - \lambda I)^T \alpha^T = \bar{0}$ (Gaussova eliminácia)
tieto riešenia sú potom vlastnými vektormi

Len pre záujemcov

```
octave> A
A =

    1.0000    0.5000
    0.5000    1.0000

octave> chiA=[1 -2 0.75];
octave> roots(chiA)
ans =

    1.5000
    0.5000

octave> polyval(chiA,1.5)
ans = 0.0
octave> polyval(chiA,0.5)
ans = 0.0
```

```
octave> eye(2)
ans =

    1    0
    0    1

octave> A - 1.5 .* eye(2)
ans =

   -0.5000    0.5000
    0.5000   -0.5000

octave> A - 0.5 .* eye(2)
ans =

    0.5000    0.5000
    0.5000    0.5000
```

```
octave> [V,L]=eig(A)
V =

   -0.70711    0.70711
    0.70711    0.70711
L =

    0.50000    0.00000
    0.00000    1.50000

octave> (A - 1.5 .* eye(2))'*V(:,2)
ans =


    0
    0

octave> (A - 0.5 .* eye(2))'*V(:,1)
ans =

    0
    0
```

Symetrická matica

- $A = A^T$
- zmena bázy má vždy charakter kosoštvorcovej deformácie s otočením a s prevrátením alebo bez:



- vlastné hodnoty sú reálne čísla (A je Hermitovská) a vlastné vektory sú na seba kolmé (uhlopriečky kosoštvorca sú na seba kolmé) a preto pre $\alpha = V^T$ $\alpha\alpha^T = \text{diag}$ takže ak vlastné vektory znormalizujeme, tak $\alpha\alpha^T = I$ a teda $\alpha^T = \alpha^{-1}$

Symetrická matica

```
octave> V
V =

-0.70711  0.70711
 0.70711  0.70711
```

```
octave> V*V'
ans =

1.00000  0.00000
0.00000  1.00000
```

```
octave> inv(V)
ans =

-0.70711  0.70711
 0.70711  0.70711
```

```
octave> V'
ans =

-0.70711  0.70711
 0.70711  0.70711
```

Štatistické spracovanie signálu

Signál: $X = \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix}$

Základné štatistické spracovanie signálu prebieha na základe ignorovania poradia vzoriek signálu, avšak na základe sledovania vzťahov medzi rôznymi hodnotami nameranými v rovnakom čase

```
octave> A=[0;1;2;5;4;3;6;7;8]
```

```
A =
```

```
0
```

```
1
```

```
2
```

```
5
```

```
4
```


```
3
```

```
6
```

```
7
```

```
8
```

```
octave> plot(A)
```



Priemer (očakávanie)

v našom prípade:

$$E(X) = \mu_X = \mu = \frac{1}{n} \sum_{i=1}^n X_i$$


Príklad: pre súčet hodu dvoch kociek je priemer 7

$$E(X - E(X)) = 0 \quad E(X - \mu) = 0$$

X sú centrovane, ak $E(X) = 0$


Priemer (očakávanie)

```
octave> mean(A)  
ans = 4  
octave> plot(A,'b',repmat(mean(A),length(A),1),'r')
```



pôvodný signál

```
octave> X=A.-mean(A);  
octave> mean(X)  
ans = 0  
octave> plot(X,'b',repmat(mean(X),length(X),1),'r')
```



centrovaný signál

Odchýľka a rozptyl

- Potrebujeme vyjadriť nakoľko sa ostatné hodnoty líšia od priemeru

- Správne riešenie: $E(|X - \mu|) = E\left(\sqrt{(X - \mu)^2}\right)$

- Približné diferencovateľné riešenie = smerodajná odchýľka

$$\sigma = \sqrt{E\left((X - \mu)^2\right)}$$

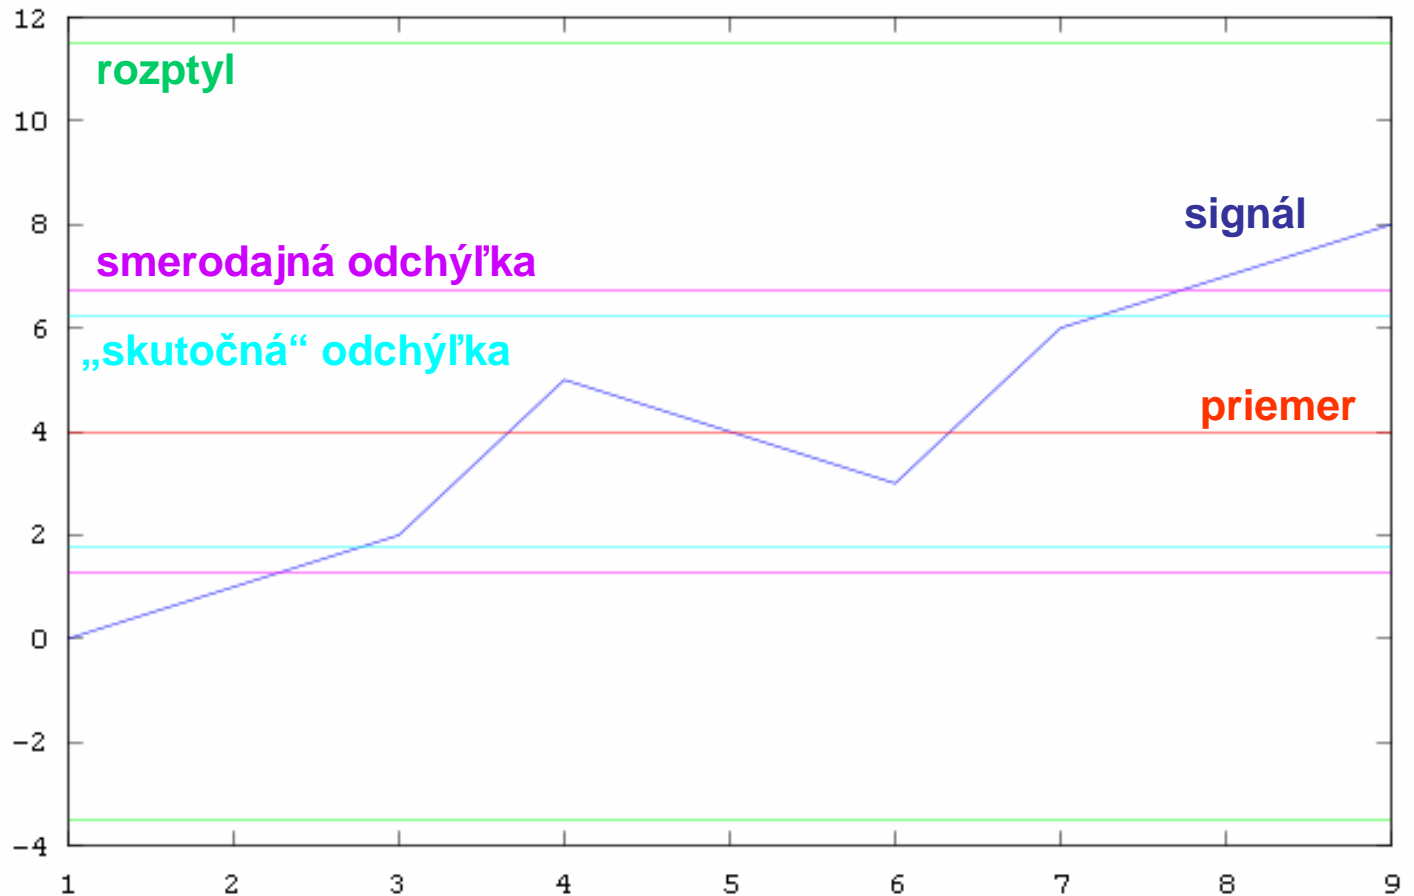
- Ľahšie sa vypočíta rozptyl

$$\sigma^2 = \text{var}(X) = V = E\left((X - \mu)^2\right)$$

Odchýľka a rozptyl

```
octave> var(A)
ans = 7.5000
octave> std(A)
ans = 2.7386
octave> std(A)*std(A)
ans = 7.5000
```

```
octave> for i=1:length(A)
> X(i)=abs(A(i)-mean(A));
> end
octave> mean(X)
```




```
plot(A,'b', repmat(mean(A),length(A),1),'r', repmat(var(A)+mean(A),length(A),1),'g', repmat(std(A)+mean(A),length(A),1),
'm', repmat(mean(X)+mean(A),length(A),1),'c', repmat(mean(A)-var(A),length(A),1),'g', repmat(mean(A)-
std(A),length(A),1),'m', repmat(mean(A)-mean(X),length(A),1),'c')
```


Kovariancia

Kovariancia dvoch signálov X a Y:


$$\text{cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y))$$





záporná



nulová



kladná



$|\text{cov}(X, Y)|$ vyjadruje
nakoľko je možné
vyjadriť

$$X = a Y + b$$

$$\text{sgn}(\text{cov}(X, Y)) = \text{sgn } a$$

Korelácia

Korelácia - Normalizácia kovariancie do $\langle -1, 1 \rangle$




$$\mathit{cor}(X, Y) = \frac{\mathit{cov}(X, Y)}{\sigma_X \sigma_Y} = \cos \varphi$$

φ je uhol medzi n -rozmernými vektormi $X - \mu_X$ a $Y - \mu_Y$


Geometrická interpretácia

$$u = X - \mu_X \quad v = Y - \mu_Y$$

$$|u| = \sigma_X \sqrt{n} \quad |v| = \sigma_Y \sqrt{n}$$




$$\cos \varphi = \frac{u \cdot v}{|u| \cdot |v|}$$




$$\varphi = \pi$$

$$\text{cor}(X, Y) = -1$$



$$\varphi = 0$$

$$\text{cor}(X, Y) = 1$$



$$\varphi = \pi/2$$

$$\text{cor}(X, Y) = 0$$

Variančno-kovariančná matica




- zovšeobecnenie rozptylu do viacerých dimenzií

$$\mathbf{X} = [X_1, X_2, \dots, X_n]$$

$$\begin{aligned} \mathbf{C}_X = \text{var}(\mathbf{X}) = \text{cov}(\mathbf{X}) &= \mathbb{E} [(\mathbf{X} - \mathbb{E}[\mathbf{X}])(\mathbf{X} - \mathbb{E}[\mathbf{X}])^\top] \\ &= \mathbb{E} [(X_i - \mu_i)(X_j - \mu_j)] \end{aligned}$$

$$= \begin{bmatrix} \mathbb{E}[(X_1 - \mu_1)(X_1 - \mu_1)] & \mathbb{E}[(X_1 - \mu_1)(X_2 - \mu_2)] & \cdots & \mathbb{E}[(X_1 - \mu_1)(X_n - \mu_n)] \\ \mathbb{E}[(X_2 - \mu_2)(X_1 - \mu_1)] & \mathbb{E}[(X_2 - \mu_2)(X_2 - \mu_2)] & \cdots & \mathbb{E}[(X_2 - \mu_2)(X_n - \mu_n)] \\ \vdots & \vdots & \ddots & \vdots \\ \mathbb{E}[(X_n - \mu_n)(X_1 - \mu_1)] & \mathbb{E}[(X_n - \mu_n)(X_2 - \mu_2)] & \cdots & \mathbb{E}[(X_n - \mu_n)(X_n - \mu_n)] \end{bmatrix}.$$

Variančno-kovariančná matica



Príklad pre 2-dim. dáta

2-dim. dáta

$$A = \begin{pmatrix} a_1^{(1)} & a_2^{(1)} \\ a_1^{(2)} & a_2^{(2)} \\ a_1^{(3)} & a_2^{(3)} \\ \vdots & \vdots \\ a_1^{(n)} & a_2^{(n)} \end{pmatrix}$$

centrované dáta

$$X = \begin{pmatrix} x_1^{(1)} & x_2^{(1)} \\ x_1^{(2)} & x_2^{(2)} \\ x_1^{(3)} & x_2^{(3)} \\ \vdots & \vdots \\ x_1^{(n)} & x_2^{(n)} \end{pmatrix} = \begin{pmatrix} \mathbf{x}^{(1)} \\ \mathbf{x}^{(2)} \\ \mathbf{x}^{(3)} \\ \vdots \\ \mathbf{x}^{(n)} \end{pmatrix} = A - E(A)$$

$$x_i^{(j)} = a_i^{(j)} - \sum_k a_i^{(k)} / n$$

$$\mathbf{x}^{(j)} = (x_1^{(j)} \ x_2^{(j)})$$

$$\mathbf{x}^{(j)T} \mathbf{x}^{(j)} = \begin{pmatrix} x_1^{(j)} x_1^{(j)} & x_1^{(j)} x_2^{(j)} \\ x_2^{(j)} x_1^{(j)} & x_2^{(j)} x_2^{(j)} \end{pmatrix}$$

$$C_X = \begin{pmatrix} \frac{\sum_i x_1^{(i)} x_1^{(i)}}{n} & \frac{\sum_i x_1^{(i)} x_2^{(i)}}{n} \\ \frac{\sum_i x_2^{(i)} x_1^{(i)}}{n} & \frac{\sum_i x_2^{(i)} x_2^{(i)}}{n} \end{pmatrix} = E(\mathbf{x}^T \mathbf{x})$$

Príklad pre 2-dim. dáta

```
octave> A = [-4 -4; -3 -3; -2 -2; 1 -1; 0 0; -1 1; 2 2; 3 3; 4 4]
```

```
A =
```

```
-4 -4
```

```
-3 -3
```

```
-2 -2
```

```
1 -1
```

```
0 0
```

```
-1 1
```



```
2 2
```

```
3 3
```

```
4 4
```

```
octave> plot(A(:,1),'g', A(:,2),'b');
```

```
octave> plot(A(:,1), A(:,2),'r+'); axis([-5 5 -5 5]);
```



Príklad pre 2-dim. dáta

```
octave> X = A - repmat(mean(A),length(A),1)
```

```
X =
```


```
-4 -4  
-3 -3  
-2 -2  
1 -1  
0 0  
-1 1  
2 2  
3 3  
4 4
```

```
octave> mean(X)
```

```
ans =  
0 0
```


```
octave> CX = cov(X)
```

```
CX =  
7.5000 7.0000  
7.0000 7.5000
```



PCA (Principal component analysis)

- Transformácia priestoru dát do priestoru, v ktorom je ich C_X diagonálna = medzi jednotlivými zložkami dát niet žiadnej korelácie




- Pre jednoduchosť prepokladáme, že dáta sú centrované (odrátime od nich ich priemer) a teda hľadáme iba otočenie o vhodný uhol, pritom zväčšenie resp. zmenšenie nevadí

PCA (Principal component analysis)

- Hľadáme teda zmenu bázy, t.j.regulárnu maticu (otočenie + zväčšenie/zmenšenie) P takú, že

$$XP = Y \text{ a } C_Y \text{ je diagonálna}$$



- centrovanie dát sa zmenou bázy nepokazí, ak bolo centrované X , bude centrované aj Y , lebo $E(Y) = E(XP) = E(X)P = \bar{0} P = \bar{0}$

PCA (Principal component analysis)

pre ľubovoľné P platí:

$$\begin{aligned} C_Y &= E(Y^T Y) = E((XP)^T X P) = E(P^T X^T X P) = \\ &= P^T E(X^T X) P = P^T C_X P \end{aligned}$$

Pre C_X sa dajú nájsť jej vlastné hodnoty a vektory (je to symetrická matica):

$$\alpha_i C_X = \lambda_i \alpha_i \quad C_X = \alpha^{-1} \Lambda \alpha \quad \alpha = \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} \quad \Lambda = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & \lambda_n \end{pmatrix}$$

α_i sú ortogonálne, dajú sa znormalizovať a potom: $\alpha^{-1} = \alpha^T$

Takže keď položíme $P = \alpha^T$ dostávame:

$$C_Y = P^T C_X P = P^T \alpha^{-1} \Lambda \alpha P = \alpha \alpha^{-1} \Lambda \alpha \alpha^T = \Lambda$$

Hľadanou transformáciou je matica, kde sú po stĺpcoch normalizované vlastné vektory C_X

PCA (Principal component analysis)

- Matica P , kde sú po stĺpcoch normalizované vlastné vektory C_x transformuje dáta do priestoru, kde sú ich jednotlivé zložky nekorelujúce $y = xP$
- absolútna hodnota vlastných hodnôt C_x dáva navyše informáciu aký vplyv má daný principálny komponent, čo môže (ale nemusí) súvisieť s jeho významnosťou

PCA

```
octave> CX=cov(X)
```

```
CX =
```

```
7.5000 7.0000  
7.0000 7.5000
```

```
octave> [V,L]=eig(CX)
```

```
V =
```

```
-0.70711 0.70711  
0.70711 0.70711
```

```
L =
```

```
0.50000 0.00000  
0.00000 14.50000
```

```
octave> Y=X*V
```

```
Y =
```



```
0.00000 -5.65685  
0.00000 -4.24264  
0.00000 -2.82843  
-1.41421 0.00000  
0.00000 0.00000  
1.41421 0.00000  
0.00000 2.82843  
0.00000 4.24264  
0.00000 5.65685
```

```
octave> CY=cov(Y)
```


```
CY =
```

```
0.50000 0.00000  
0.00000 14.50000
```

významnější
komponent




PCA



pôvodné
dáta

PCA



transformované
dáta

PCA (Principal component analysis)

Príklad použitia:



- rozpoznávanie tvárí

Fotky 60x60

Sada 26 fotiek

(bez predspracovania)

z 3600 bodov PCA dala (iba!)
25 hlavných komponentov
(zvyšných 3575 má takmer
nulovú vlastnú hodnotu)



Použitie PCA

- Rozpoznávanie
- Stratová kompresia
- Zmenšenie dimenzie dát
- Oddeľovanie zložiek signálu
- Odšumenie signálu
- Rekonštrukcia dát

Aplikovateľnosť je obmedzená numerickou stabilitou v rámci danej aplikačnej domény

Ďakujem za pozornosť !

Principal Component Analysis

Andrej Lúčný

Katedra aplikovanej informatiky FMFI UK

lucny@fmph.uniba.sk

<http://www.fmph.uniba.sk/~lucny>