

Klasifikace a rozpoznávání


Extrakce příznaků

Extrakce příznaků - parametrizace

- Poté co jsme ze snímače obdržely data která jsou relevantní pro naši klasifikační úlohu, je potřeba je přizpůsobit potřebám rozpoznávače
- Klasifikátory mají rády parametry které jsou:
 - Gaussovského rozložení (většinou vícerozměrného)
 - Nekorelované
 - Nízkodimenzionální


Příklad parametrizace pro 2D vstupní vektory

- Mějme vzorky (příklady) 2D rozložení pro dvě třídy.




Příklad parametrizace pro 2D vstupní vektory

- Rozložení není příliš gaussovské.
- Provedeme třetí odmocninou obou koeficientů.




Příklad parametrizace pro 2D vstupní vektory

- Prostor se komprimuje – nelineárně deformuje...




Příklad parametrizace pro 2D vstupní vektory

- ... a rozložení pro každou třídu je nyní gaussovské.
- Koeficienty jsou ale korelované.
- Je vhodné prostor otočit tak aby se koeficienty dekorelovaly.



Příklad parametrizace pro 2D vstupní vektory

- Nyní jsou koeficienty dekorelovány.
- Svislá dimenze je navíc zbytečná, protože třídy se v ní zcela překrývají.



Gaussovské rozložení (jednorozměrné)


Evaluation:

$$p(x) = \mathcal{N}(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

ML odhad parametrů
(Trénování):


$$\hat{\mu}_{ML} = \frac{1}{N} \sum_n x_n$$

$$\hat{\sigma}_{ML}^2 = \frac{1}{N} \sum_n (x_n - \hat{\mu}_{ML})^2 = \frac{1}{N} \sum_n x_n^2 - \hat{\mu}_{ML}^2$$



Gaussovské rozložení (vícerozměrné)

$$p(x_1, \dots, x_D) = \mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Sigma}|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}-\boldsymbol{\mu})}$$







ML odhad of parametrů:

$$\boldsymbol{\mu} = \frac{1}{T} \sum_i \mathbf{x}_i$$

$$\boldsymbol{\Sigma} = \frac{1}{T} \sum_i (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T$$

Plná a diagonální kovarianční matice



Diagonální kovarianční matice

$$\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Sigma}|}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

Pokud je $\boldsymbol{\Sigma}$ diagonální matice s koeficienty v diagonále $\sigma_i^2 \rightarrow$


$$\begin{aligned} \mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) &= \frac{1}{\sqrt{(2\pi)^D \prod_{i=1}^D \sigma_i^2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^D \frac{(x_i - \mu_i)^2}{\sigma_i^2} \right\} \\ &= \left(\prod_{i=1}^D \frac{1}{\sqrt{2\pi\sigma_i^2}} \right) \left(\prod_{i=1}^D \exp \left\{ -\frac{1}{2} \frac{(x_i - \mu_i)^2}{\sigma_i^2} \right\} \right) \\ &= \prod_{i=1}^D \mathcal{N}(x_i; \mu_i, \sigma_i^2) \end{aligned}$$

Diagonální kovarianční matice

$P(A, B) = P(A)P(B) \Rightarrow$ Jevy A a B jsou statisticky nezávislé

$$\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \prod_{i=1}^D \mathcal{N}(x_i; \mu_i, \sigma_i^2)$$

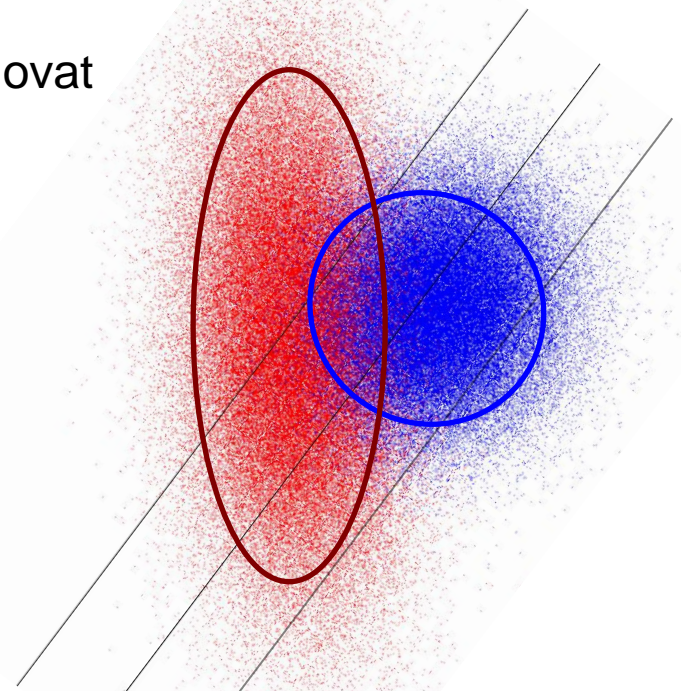
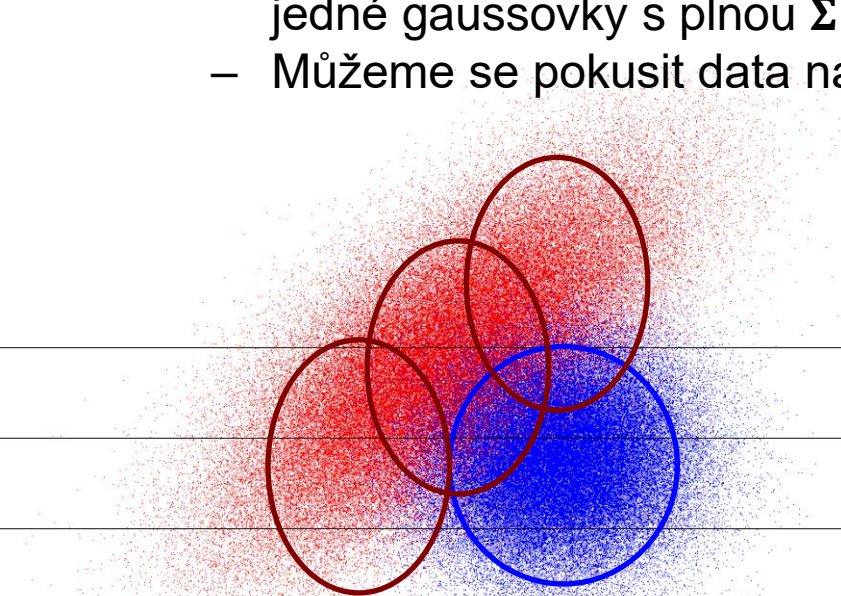
Koeficienty x_i příznakového vektoru \mathbf{x} jsou statisticky nezávislé.



Diagonální kovarianční matice

Proč nás zajímá?


- Pomůže nám pochopit význam plné kovarianční matice v gaussovském rozložení
- Úspora parametrů při modelování dat
- Pokud jsou data korelována (viz červená třída na prvním obr.)
 - Zvláště pro vysoce dimenzionální příznaky, modelování pomocí směsi gaussovských rozložení s diagonální Σ může být úspornější než použití jedné gaussovky s plnou Σ
 - Můžeme se pokusit data natočit - dekorelovat



Skalární součin

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad \mathbf{b} = [b_1 \quad b_2]$$

$$\mathbf{b}\mathbf{x} = [b_1 \quad b_2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = b_1x_1 + b_2x_2$$




Rotace vektoru

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{bmatrix} = \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix}$$

Nechť \mathbf{b}_1 a \mathbf{b}_2 jsou ortonormální báze


- Vektory jsou na sebe kolmé
- Mají délku $|\mathbf{b}_1| = |\mathbf{b}_2| = 1$

Potom $\mathbf{y} = \mathbf{B}\mathbf{x}$ je otočený vektor \mathbf{x} , kde \mathbf{b}_1 a \mathbf{b}_2 ukazují v původním prostoru směry nových os



Projekce vektoru

- Necht' \mathbf{B} je matice ortonormálních bází a $\bar{\mathbf{B}}$ matice tvořena pouze několika řádky (bázemi) matice \mathbf{B} .
- Potom $\mathbf{y} = \bar{\mathbf{B}}^T \bar{\mathbf{B}} \mathbf{x}$ je projekce vektoru \mathbf{x} do bází $\bar{\mathbf{B}}$.



Vlastní čísla a vektory

λ je vlastní číslo a \mathbf{e} je odpovídající vlastní vektor čtvercové matice Σ , pokud platí:

$$\Sigma \mathbf{e} = \mathbf{e} \lambda$$

$D \times D$ matice má (nanejvýš) D různých vlastních čísel. Necht' je Λ diagonální matice všech vlastních čísel a matice \mathbf{E} obsahuje ve sloupcích odpovídající vlastní vektory.

$$\Sigma \mathbf{E} = \mathbf{E} \Lambda$$

Nás bude zajímat speciální případ kdy matice Σ je symetrická. Potom budou sloupce matice \mathbf{E} tvořit ortonormální báze. Pro takovou matici potom platí: $\mathbf{E}^T \mathbf{E} = \mathbf{E}^{-1} \mathbf{E} = \mathbf{I}$ kde \mathbf{I} je jednotková matice. Tedy platí následující rozklady matic:

$$\mathbf{E}^T \Sigma \mathbf{E} = \Lambda \quad \Sigma = \mathbf{E} \Lambda \mathbf{E}^T$$

μ transformovaných dat

- Jak se změní odhady střední hodnoty a kovarianční matice pokud původní data transformujeme: $\mathbf{y} = \mathbf{A}\mathbf{x}$

$$\begin{aligned}\boldsymbol{\mu}_y &= \frac{1}{N} \sum_{n=1}^T \mathbf{A}\mathbf{x}_n \\ &= \mathbf{A} \frac{1}{N} \sum_{n=1}^T \mathbf{x}_n \\ &= \mathbf{A}\boldsymbol{\mu}_x\end{aligned}$$


Σ transformovaných dat

$$\begin{aligned}\Sigma_y &= \frac{1}{N} \sum_{n=1}^T (\mathbf{A}\mathbf{x}_n - \boldsymbol{\mu}_y)(\mathbf{A}\mathbf{x}_n - \boldsymbol{\mu}_y)^T \\ &= \frac{1}{N} \sum_{n=1}^T (\mathbf{A}\mathbf{x}_n - \mathbf{A}\boldsymbol{\mu}_x)(\mathbf{A}\mathbf{x}_n - \mathbf{A}\boldsymbol{\mu}_x)^T \\ &= \mathbf{A} \left\{ \frac{1}{N} \sum_{n=1}^T (\mathbf{x}_n - \boldsymbol{\mu}_x)(\mathbf{x}_n - \boldsymbol{\mu}_x)^T \right\} \mathbf{A}^T \\ &= \mathbf{A}\Sigma_x\mathbf{A}^T\end{aligned}$$

Co se stane když jako \mathbf{A} použijeme transponovanou matici vlastních vektorů kovarianční matice Σ_x ? (Proč transponovanou? Protože vlastní vektory máme ve sloupcích a ne v řádcích). Jaký význam mají vlastní čísla?


Analýza hlavních komponent

(Principal Component Analysis - PCA)



Analýza hlavních komponent

- Umožňuje:
 - Dekorelaci – vlastní vektory kovarianční matice definují souřadný systém ve kterých jsou data dekorelována – mají diagonální kovarianční matici
 - Redukci dimenzí – promítnutí dat do pouze několika vlastních vektorů odpovídajících největším vlastním číslům (směry s největší variací) umožní optimální rekonstrukci dat s nejmenší kvadratickou chybou (mean square error - MSE)
 - Redukce dimenzí provádíme pokud věříme, že v některých směrech není užitečná informace ale pouze (gaussovský) šum s nízkou variabilitou.




Interpretace Σ v gaussovském rozložení

$$\begin{aligned}\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) &= \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Sigma}|}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\} \\ &= \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Sigma}|}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \mathbf{E} \boldsymbol{\Lambda}^{-1} \mathbf{E}^T (\mathbf{x} - \boldsymbol{\mu}) \right\} \\ &= \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Lambda}|}} \exp \left\{ -\frac{1}{2} (\mathbf{E}^T \mathbf{x} - \mathbf{E}^T \boldsymbol{\mu})^T \boldsymbol{\Lambda}^{-1} (\mathbf{E}^T \mathbf{x} - \mathbf{E}^T \boldsymbol{\mu}) \right\}\end{aligned}$$


PCA - Příklad

- Obrázky 100x100 pixelů – 10000 dimensionální vektory




- Střední hodnota, vlastní čísla a vlastní vektory

$$\mu \quad \lambda_1=3.4 \cdot 10^5 \quad \lambda_2=2.8 \cdot 10^5 \quad \lambda_3=2.4 \cdot 10^5 \quad \lambda_4=1.6 \cdot 10^5$$




- Střední hodnota, vlastní čísla a vlastní vektory

Originál M = 1 M=10 M=50 M=250



PCA - Příklad

- Jakou dimenzi si PCA vybere na tomto příkladě?
- Bude to výhodné pro klasifikaci tříd?




Lineární diskriminační analýza

- Opět se pokusíme promítnout data pouze do určitého směru: $y = \mathbf{w}^T \mathbf{X}$
- Tentokrát ale budeme chtít aby v tomto směru byly separovány třídy.
- Intuitivně by nás mohlo napadnout vybrat směr ve kterém jsou nejlépe odděleny průměty středních hodnot tříd \mathbf{m}_1 a \mathbf{m}_2 . Hledáme tedy \mathbf{w} , které maximalizuje:



$$m_2 - m_1 = \mathbf{w}^T (\mathbf{m}_2 - \mathbf{m}_1)$$

$$m_k = \mathbf{w}^T \mathbf{m}_k$$



Lineární diskriminační analýza

- Lze však najít i lepší směr:




- Snažíme se data promítnout do takového směru, kde
 - Maximalizujeme (čtverec) vzdálenosti mezi středními hodnotami tříd
 - Nebo-li varianci mezi třídami
 - Minimalizujeme průměrnou varianci tříd

- Maximalizujeme tedy
$$J(\mathbf{w}) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2}$$

$$s_k^2 = \sum_{n \in \mathcal{C}_k} (y_n - m_k)^2$$

Lineární diskriminační analýza



Lineární diskriminační analýza

- LDA dimenze dány vlastními vektory matice $\Sigma_{wc}^{-1}\Sigma_{ac}$
- Σ_{ac} – kovarianční matice spočítaná se středních hodnot tříd
- Σ_{wc} – průměrná kovarianční matice tříd
- Lze zobecnit pro více tříd – vlastní vektory s největšími vlastními čísly odpovídají směrům ve kterých jsou třídy nejlépe separovány
- Pro J tříd bude pouze J-1 vlastních čísel nenulových
- Pokud mají všechny třídy gaussovské rozložení se stejnou kovarianční maticí, LDA transformace transformuje prostor tak, že mohou být třídy optimálně modelovány gaussovským rozložením s diagonální kovarianční maticí

$$\hat{\Sigma}_{wc} = \frac{1}{N} \sum_{j=1}^J N_j \hat{\Sigma}^{(j)} \quad \hat{\Sigma}^{(j)} = \frac{1}{N_j} \sum_{i=1}^{N_j} (\mathbf{x}_i^{(j)} - \hat{\boldsymbol{\mu}}^{(j)})(\mathbf{x}_i^{(j)} - \hat{\boldsymbol{\mu}}^{(j)})^T$$

$$\hat{\Sigma}_{ac} = \frac{1}{N} \sum_{j=1}^J N_j (\hat{\boldsymbol{\mu}}^{(j)} - \hat{\boldsymbol{\mu}})(\hat{\boldsymbol{\mu}}^{(j)} - \hat{\boldsymbol{\mu}})^T \quad \hat{\boldsymbol{\mu}}^{(j)} = \frac{1}{N_j} \sum_{i=1}^{N_j} \mathbf{x}_i^{(j)}$$

Lineární diskriminační analýza

- Vlastních vektor \mathbf{w}_i odpovídá určitému směru v prostoru vstupních dat
- Odpovídající vlastní číslo λ_i udává poměr mezi variancím
 - středních hodnot tříd
 - průměrnou variancím v rámci třídve směru \mathbf{w}_i



$$\lambda_i = \frac{\mathbf{w}_i^T \boldsymbol{\Sigma}_{ac} \mathbf{w}_i}{\mathbf{w}_i^T \boldsymbol{\Sigma}_{wc} \mathbf{w}_i}$$

- LDA najde první směr \mathbf{w}_1 kde je tento poměr λ_1 největší, druhý směr \mathbf{w}_2 kde je tento poměr λ_2 druhý největší, atd.
- Místo hledání vlastních čísel a vektorů matice $\boldsymbol{\Sigma}_{wc}^{-1} \boldsymbol{\Sigma}_{ac}$ lze řešit jako *zobecněný problém vlastních čísel* (Generalized eigen value problem) pro které existují standardní implementace (*scipy.linalg.eigh*)

$$\boldsymbol{\Sigma}_{ac} \mathbf{w}_i = \lambda_i \boldsymbol{\Sigma}_{wc} \mathbf{w}_i$$

$$\boldsymbol{\Sigma}_{ac} \mathbf{W} = \boldsymbol{\Sigma}_{wc} \mathbf{W} \boldsymbol{\Lambda}$$


Lineární diskriminační analýza




Transformace pomocí W

Protože kreslíme elipsy v rozsahu $\pm 2x$ standardní odchylka $\sqrt{\lambda_1}$


Lineární diskriminační analýza



PCA pro Σ_{WC}




trasformace E_{WC} jsou
vlastní vektory Σ_{WC}




trasformace $\Lambda_{WC}^{-\frac{1}{2}}$ jsou odmocniny
inverzních vlastních čísel Σ_{WC}




$$W = E_{AC}^T \Lambda_{WC}^{-\frac{1}{2}} E_{WC}^T \Downarrow$$



PCA pro $\overline{\Sigma}_{AC}$



trasformace E_{AC} jsou
vlastní vektory $\overline{\Sigma}_{AC}$





$$\overline{\Sigma}_{WC} = I$$


$$\overline{\Sigma}_{AC} = \Lambda_{WC}^{-\frac{1}{2}} E_{WC}^T \Sigma_{AC} E_{WC} \Lambda_{WC}^{-\frac{1}{2}}$$

LDA a lineární klasifikátor

Dvě třídy s gaussovským rozložením se stejnou kovarianční maticí jsou opravdu optimálně oddělitelné lineárním klasifikátorem (přímkou, rovinou, hyper-rovinou)




Extrakce příznaku pro řeč - MFCC (Mel frequency cepstral coefficients)




- Nejprve řečový signál rozdělíme do asi 20ms překrývajících se segmentů


a) Segment of speech signal for vowel 'iy'




b) Speech segment after preemphasis and windowing




c) Fourier spectrum of speech segment



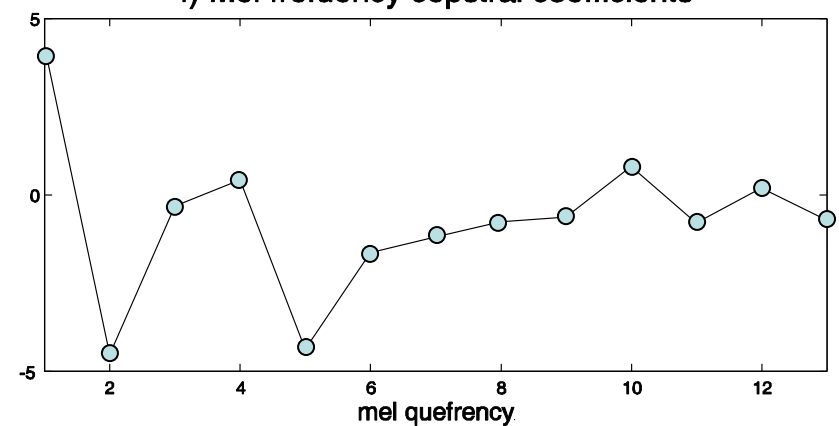
d) Filter bank energies - smoothed spectrum




e) Log of filter bank energies




f) Mel frequency cepstral coefficients




Původní signál




Logaritmický výstup z banky filtrů – je třeba již jen dekorelovat




a) Eigen values



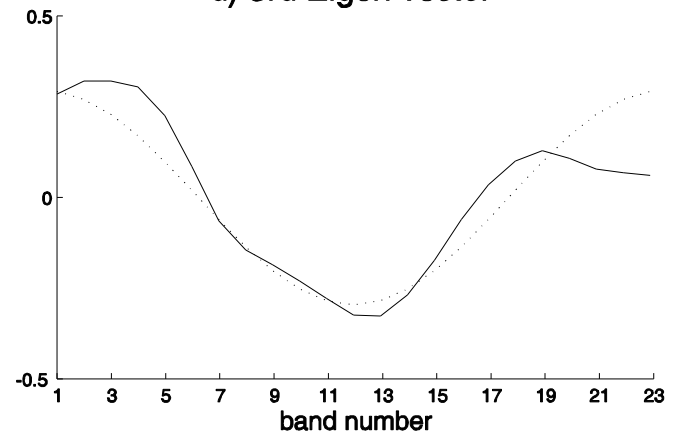
b) 1st Eigen vector




c) 2nd Eigen vector




d) 3rd Eigen vector



e) 4th Eigen vector



f) 5th Eigen vector



Singular Value Decomposition - SVD

$$A = UDV^T$$

- **A** je jakákoli $m \times n$ matice
- **U** je $m \times n$ matice kde sloupce jsou ortonormální báze
- **V** je $n \times n$ matice kde sloupce jsou ortonormální báze
- **D** je $n \times n$ je diagonální matice

- Předpokládejme, že matice **A** je matice s příznakovými vektory v řádcích s již odečtenou střední hodnotou $\rightarrow \Sigma = A^T A$
- Potom z následujících vztahů vyplývá, ze:
 - **V** jsou vlastní vektory Σ
 - Diagonála **D** obsahuje odmocniny z vlastních čísel Σ (variance ve směrech vlastních vektorů)

$$A^T A = VDU^T UDV^T = VD^2V^T$$

$$AA^T = UDV^T VDU^T = UD^2U^T$$