

Parametrizace řeči

Lukáš Burget ÚPGM FIT VUT Brno, burget@fit.vutbr.cz

FIT VUT Brno

Plán

- Cíle parametrizace
- Mel frekvenční kepstrální koeficienty
- Parametrizace odvozená na datech
- Dynamické koeficienty
- Temporální filtrace

Cíl parametrizace

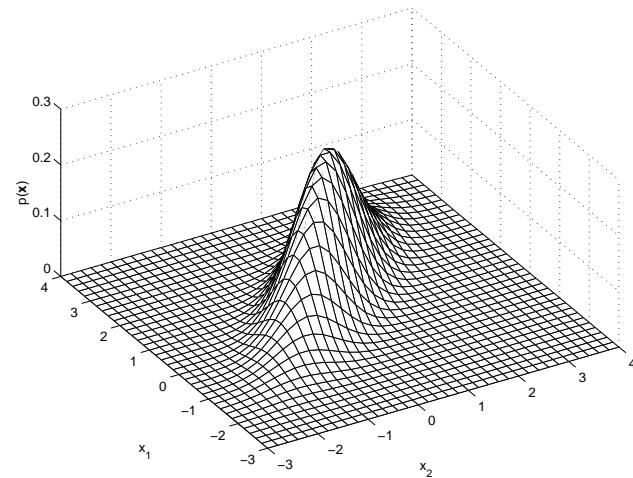
Přizpůsobení vstupních dat potřebám rozpoznávače

Rozpoznávače mají rády parametry, které jsou

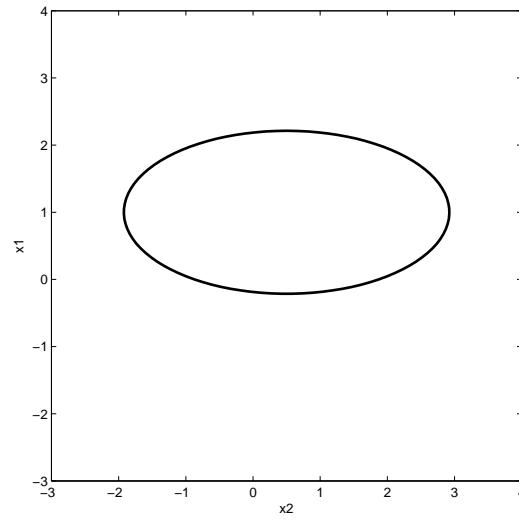
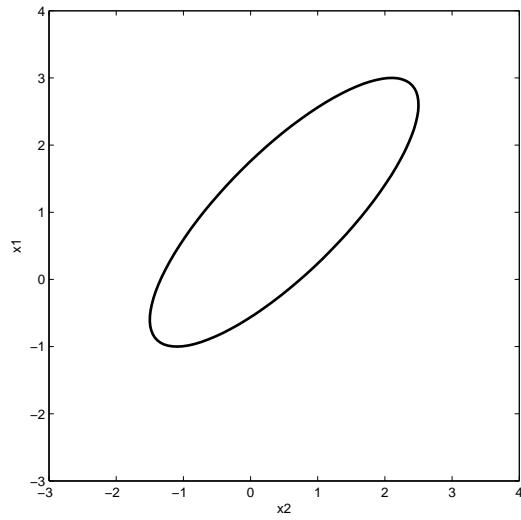
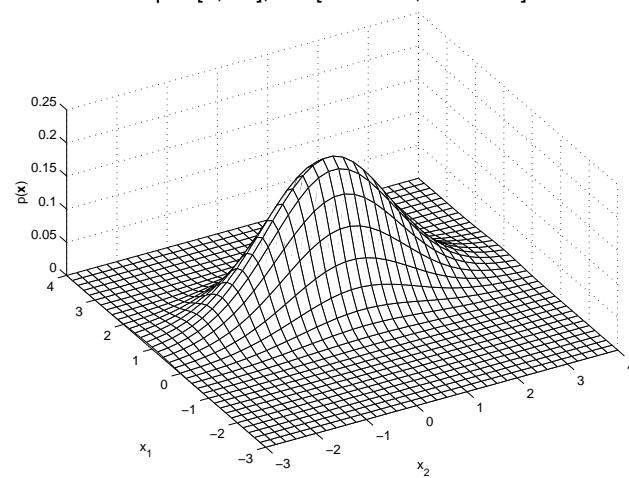
1. gaussovského rozložení (většinou vícerozměrného),
2. dekorelované,
3. málo dimenzionální.

Dvourozměrné gaussovské rozložení

$$\mu = [1; 0.5]; \Sigma = [1 0.8; 0.8 1]$$

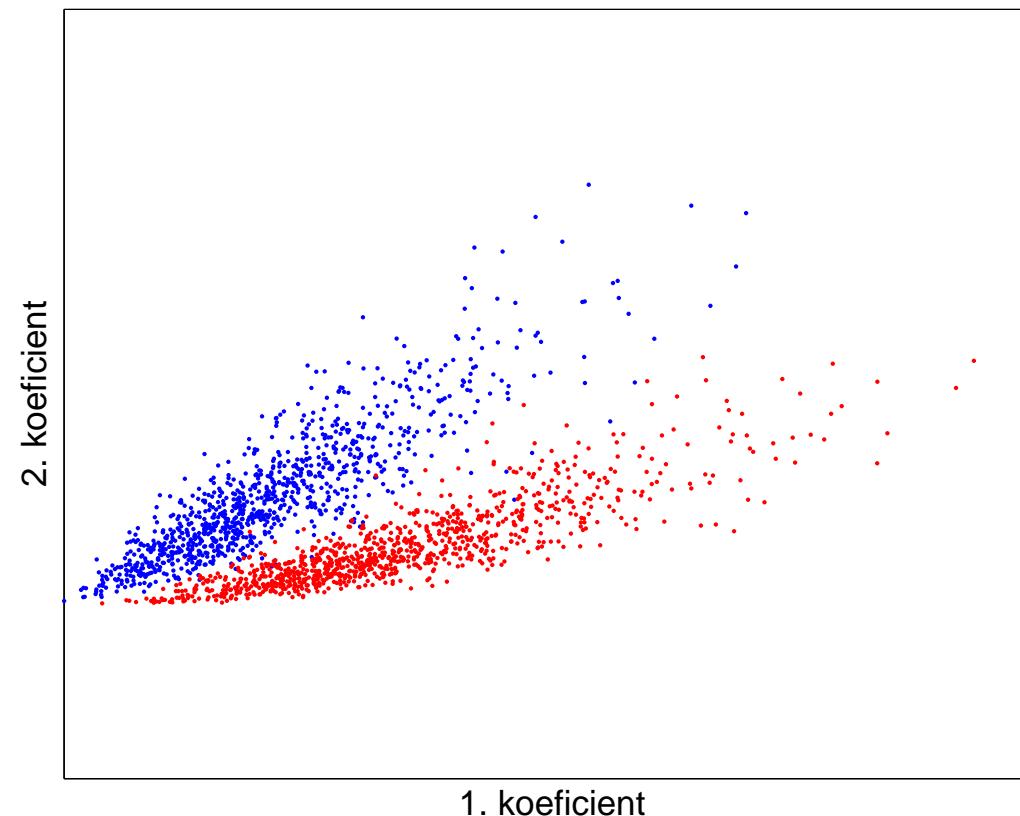


$$\mu = [1; 0.5]; \Sigma = [0.3679 0; 0 1.4679]$$



Příklad parametrizace pro 2D vstupní vektory

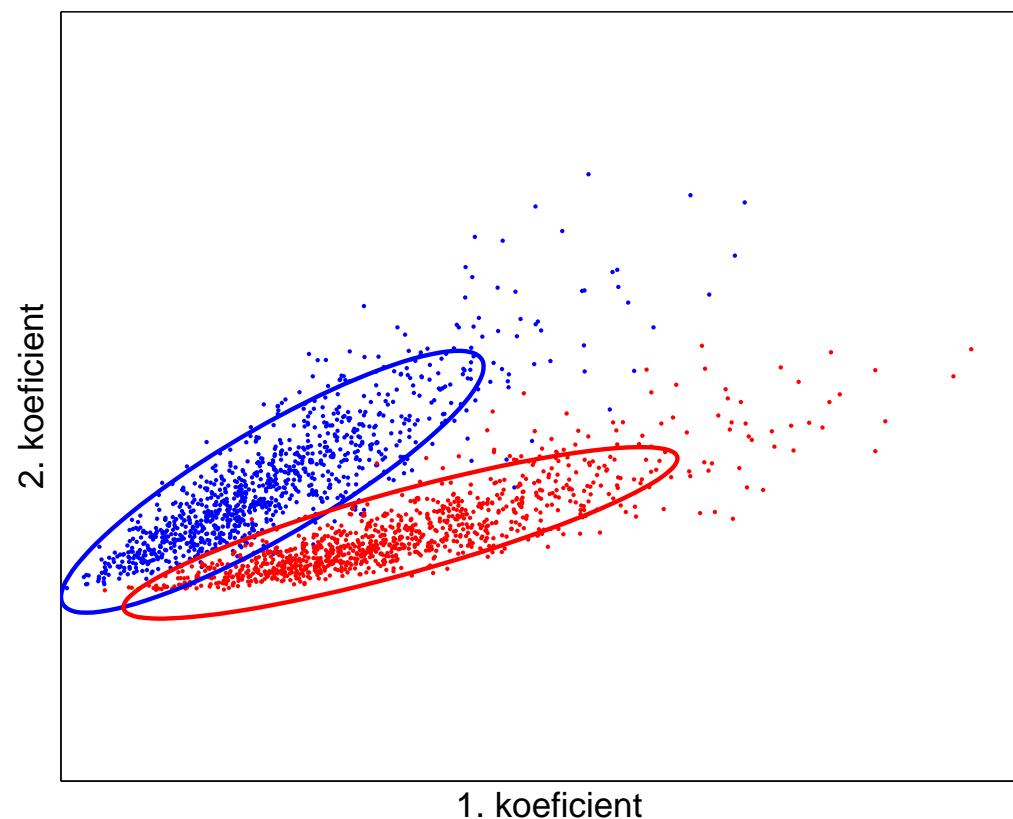
Mnějme vzorky (příklady) 2D rozložení pro dvě třídy.



Příklad parametrizace pro 2D vstupní vektory

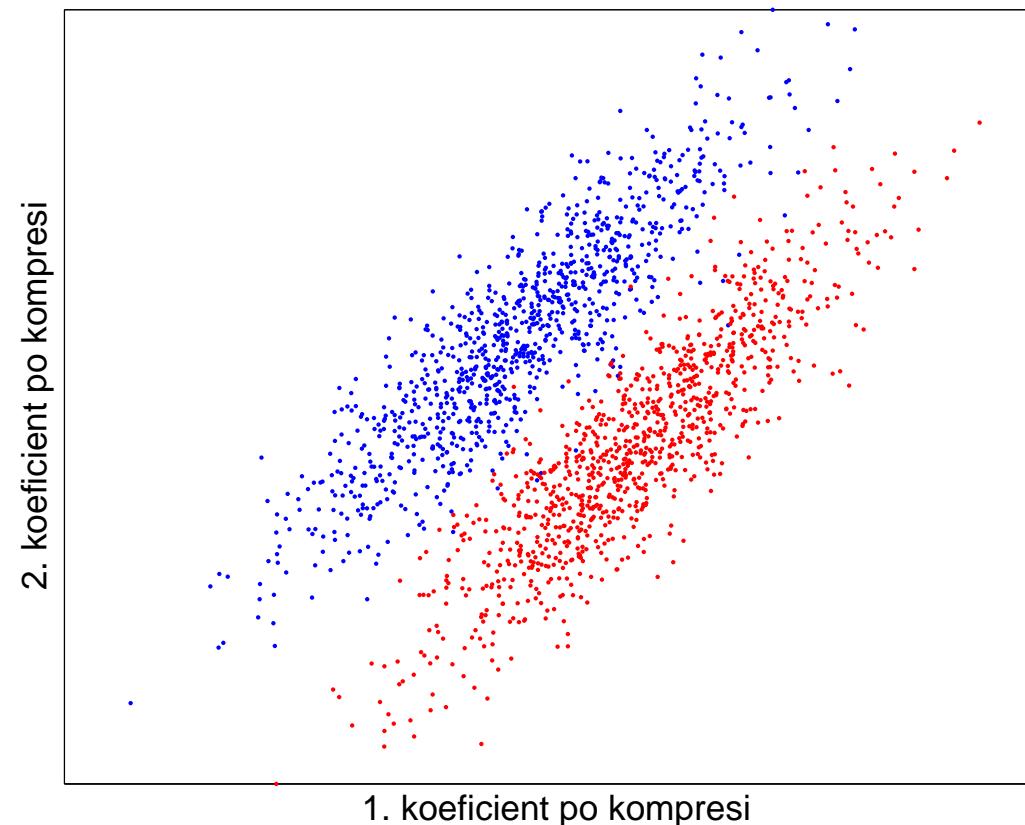
Rozložení není příliš gausovské.

Provedeme třetí odmocninou obou koeficientů.



Příklad parametrizace pro 2D vstupní vektory po kompresi

Prostor se komprimuje - nelineárně deforme...

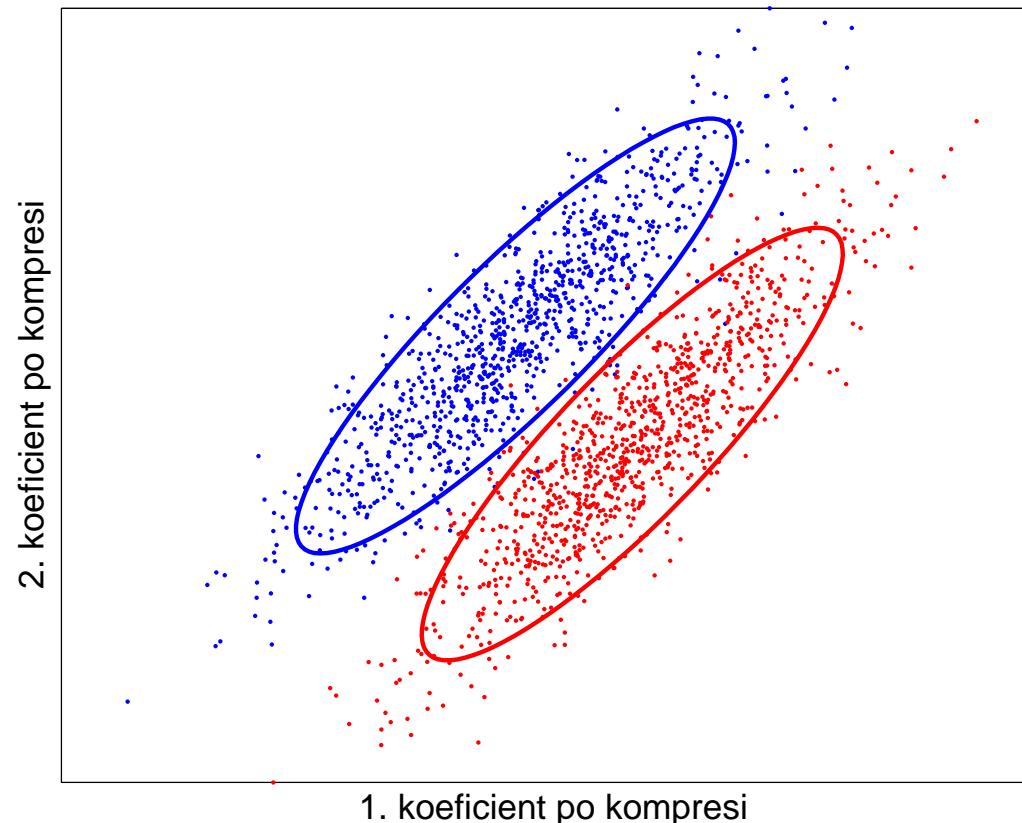


Příklad parametrizace pro 2D vstupní vektory po kompresi

... a rozložení pro každou třídu je nyní gausovské.

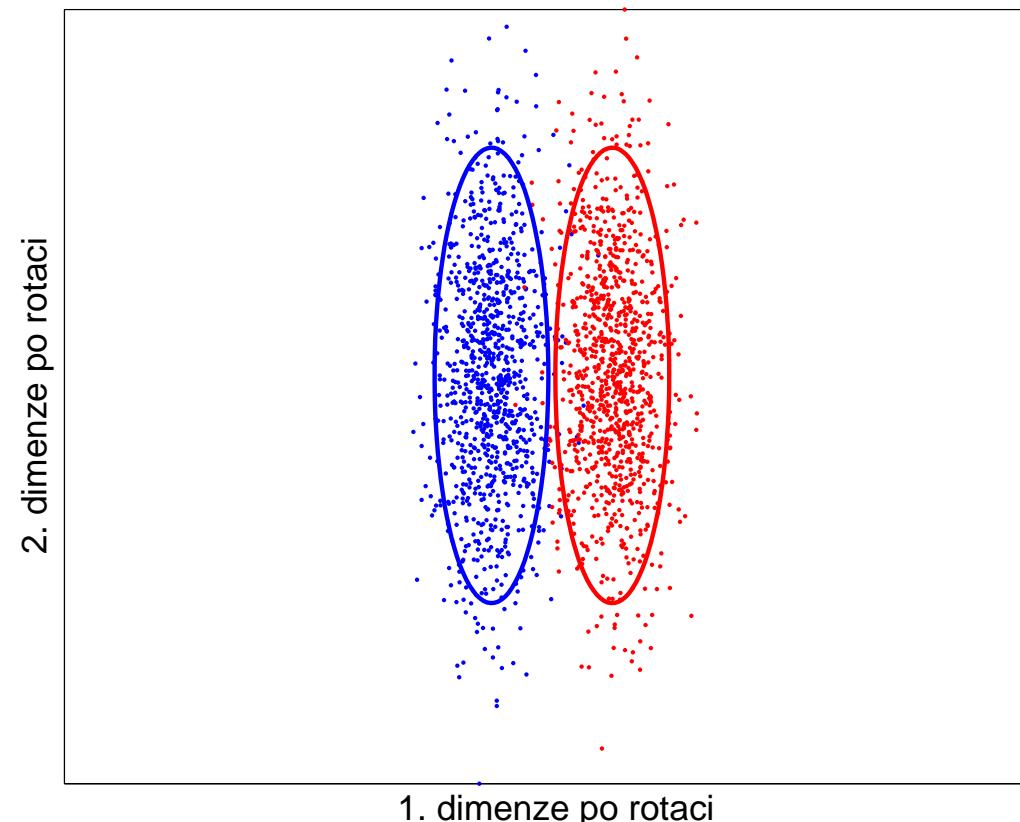
Koeficienty jsou ale korelované.

Je vhodné prostor otočit tak aby se koeficienty dekorelovaly.



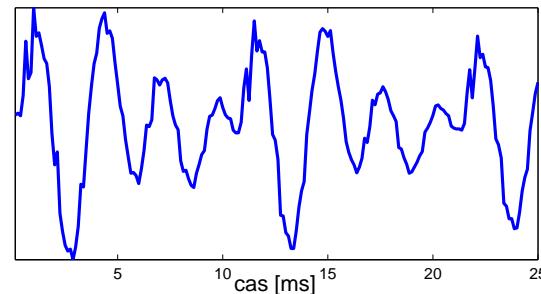
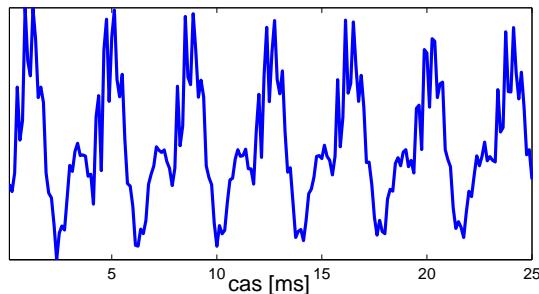
Příklad parametrizace pro 2D vstupní vektory po dekorelaci

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



MFCC - Segmentace

Řečový signál je nejprve "rozsekán" do segmentů o délce cca 25ms a každý takový segment je pak zpracován nezávisle. Jednotlivé kroky MFCC parametrizace si budeme demonstrovat na dvou takových segmentech. Oba segmenty představují foném 'iy' ve slově 'three', jeden je však vysoven ženou a druhý mužem.

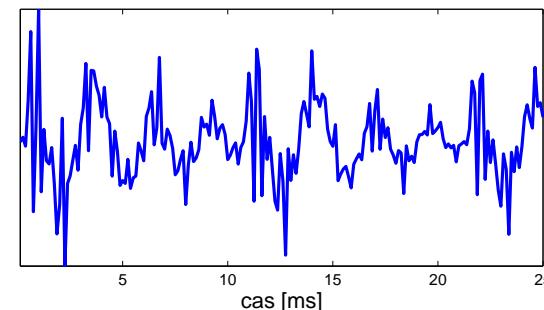
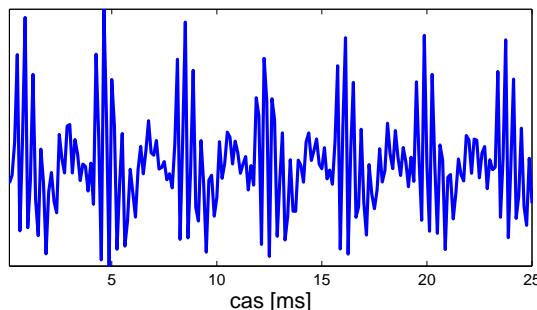
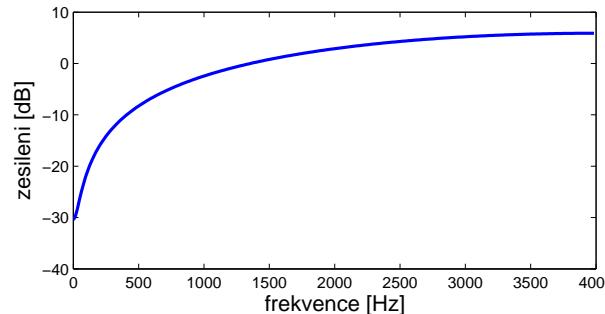
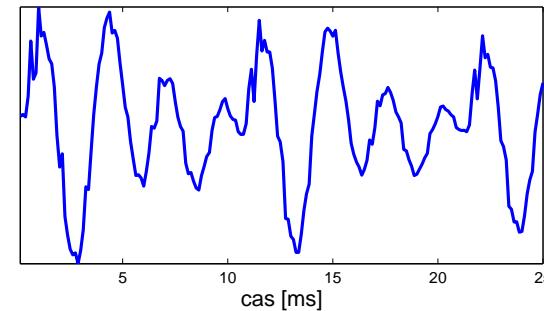
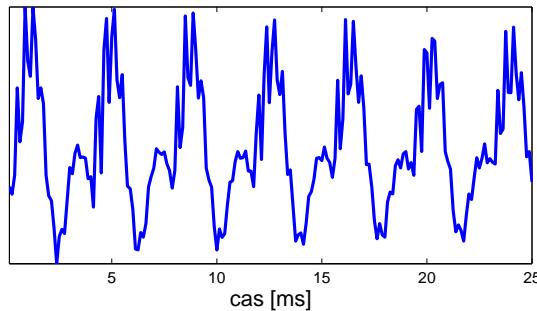


MFCC - Preemfáze

Zvuky o stejné energii na různých kmitočtech člověk slyší různě hlasitě.

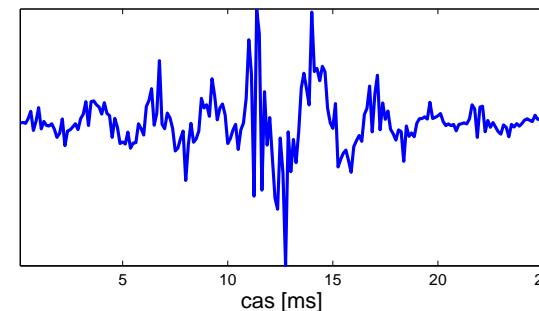
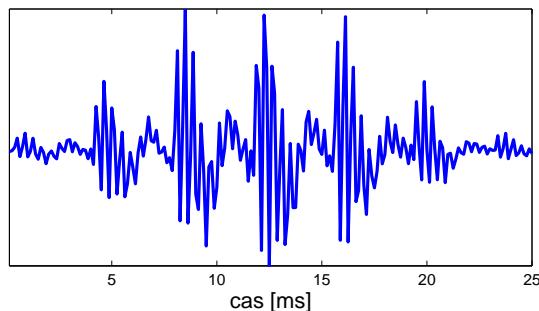
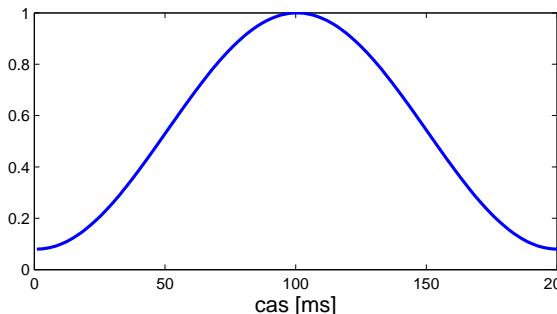
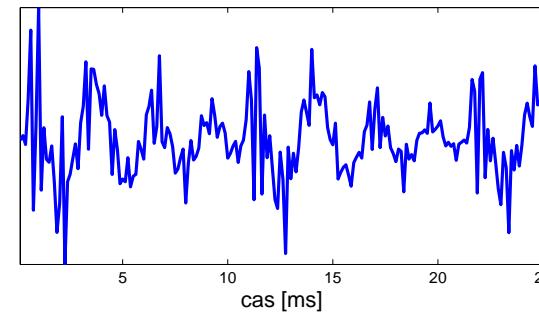
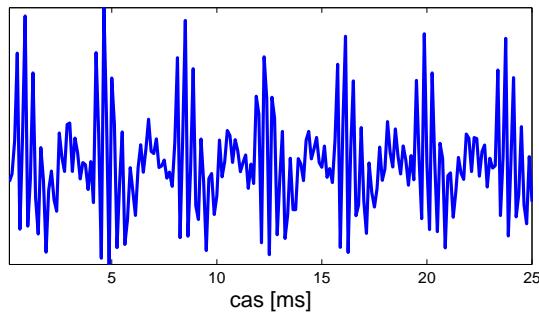
(viz sin_20_200_2000_Hz.wav)

Proto se signál filtruje horní propustí.

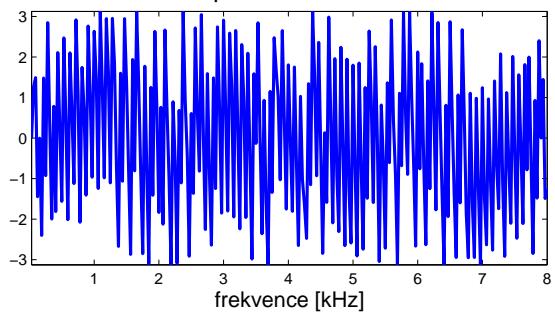
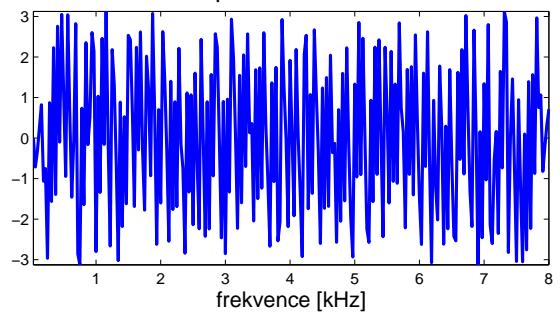
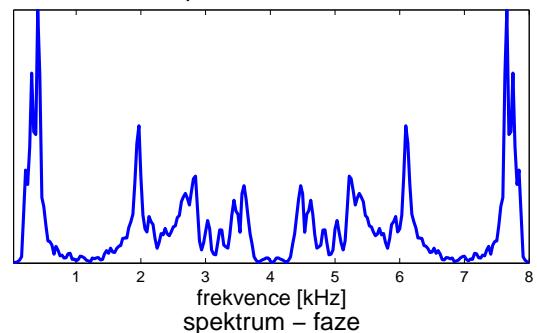
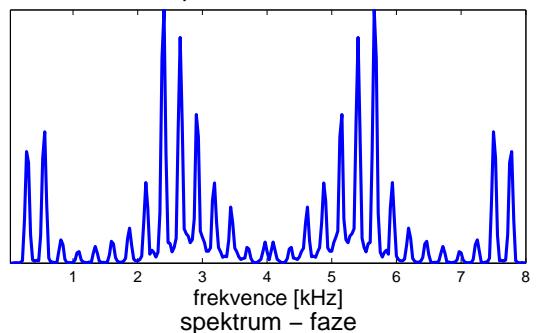
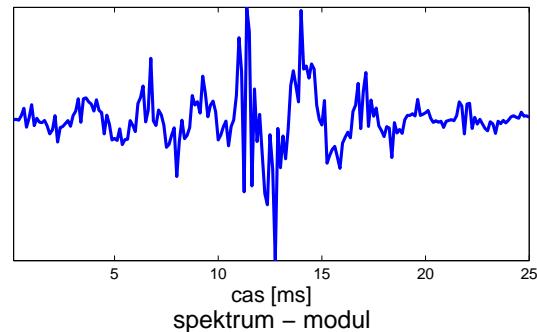
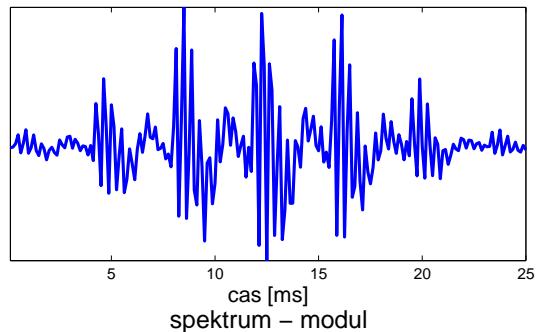


MFCC - Váhování hammingovým oknem

Pro jednotlivé segmenty řeči budeme chtít sočítat jejich spektra. Diskontinuity na krajích segmentu vedou ke zkreslení (zašumění spekter). To lze kompenzovat váhováním segmentu např. hammingovým oknem.

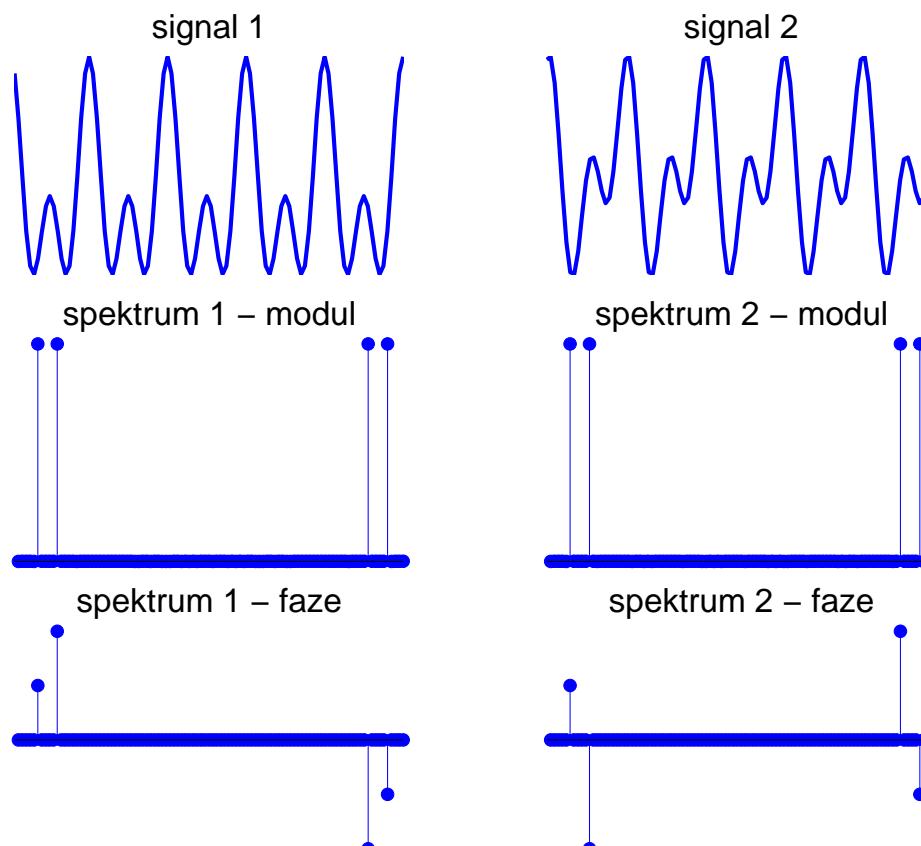


MFCC - Spektrum



Součet dvou sinusovek pro různé fázové posuny

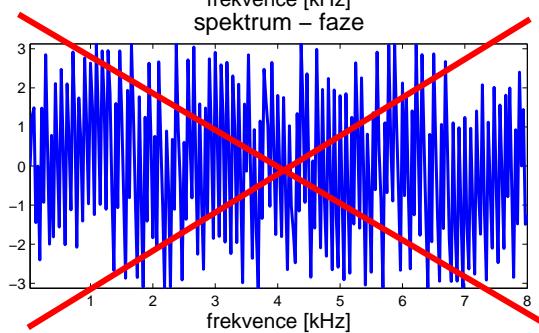
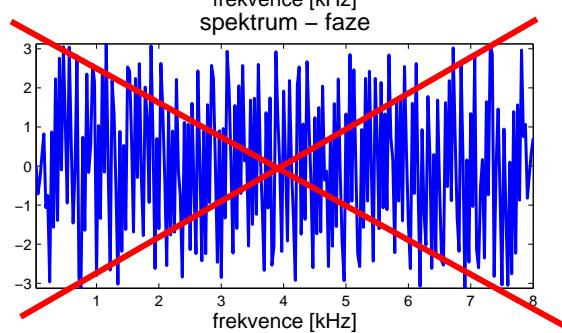
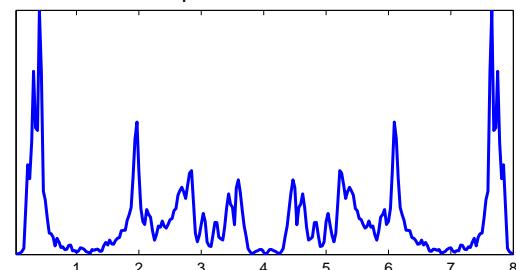
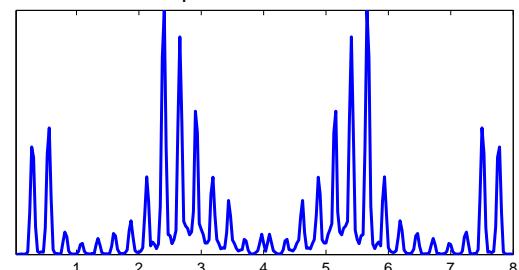
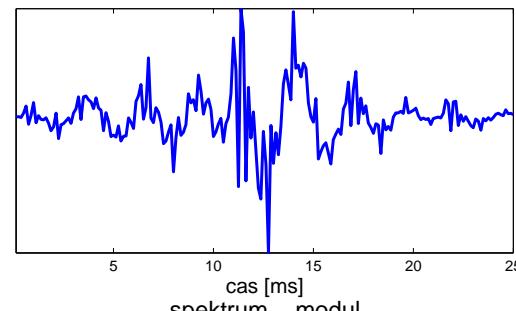
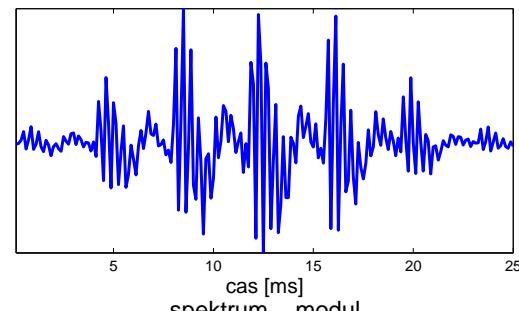
Dva různé součty sinusovek o stejné amplitudě a frekvencích 400 a 800 Hz pro různé vzájemné posunutí obou sinusovek. (viz. different_phase.wav)



Člověk přiliš neslyší rozdíly ve fázy.

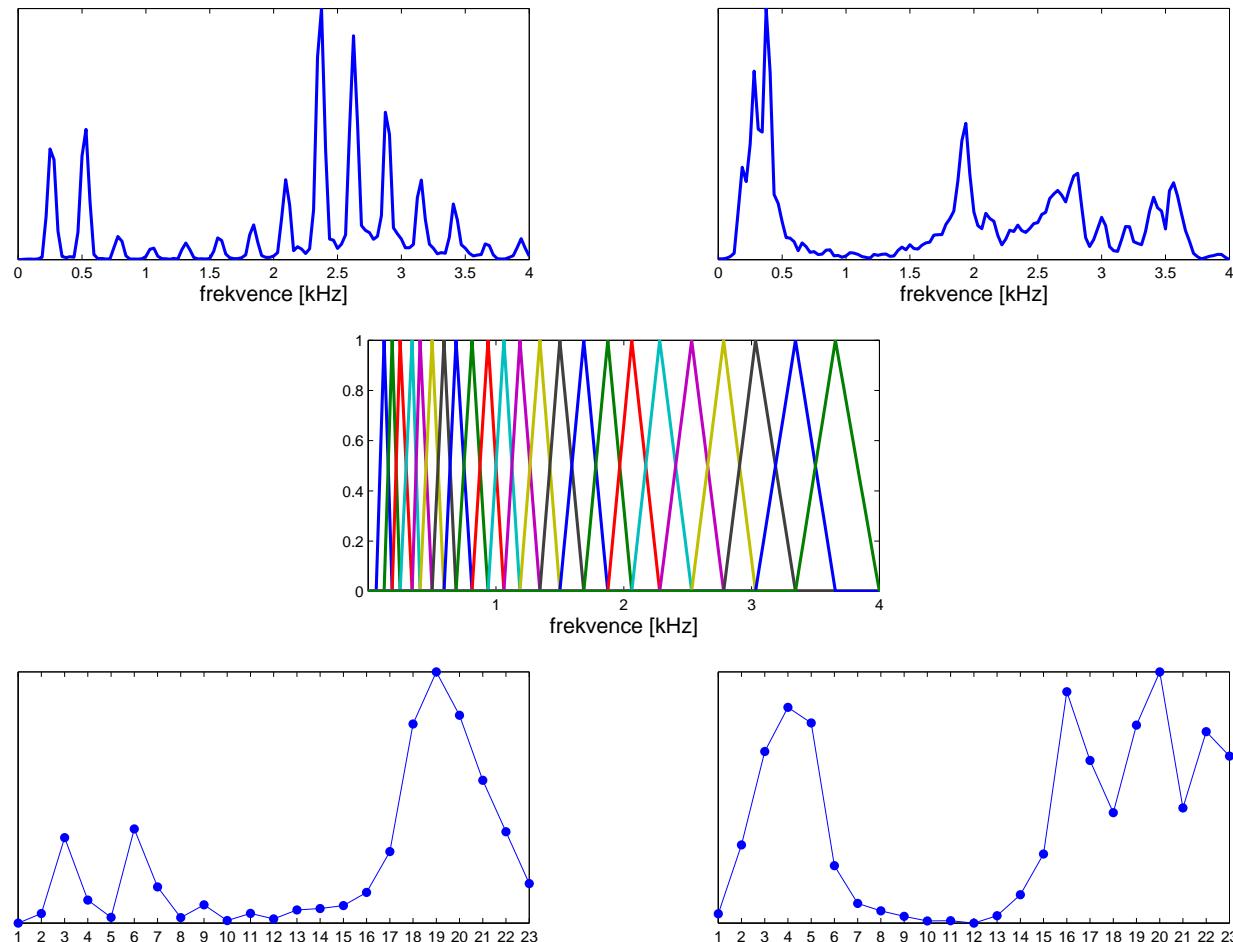
MFCC - Spektrum

Proto informaci o fázi zahodíme
a také budeme dále používat pouze polovinu simetrického spektra



MFCC - Mel banka filtru

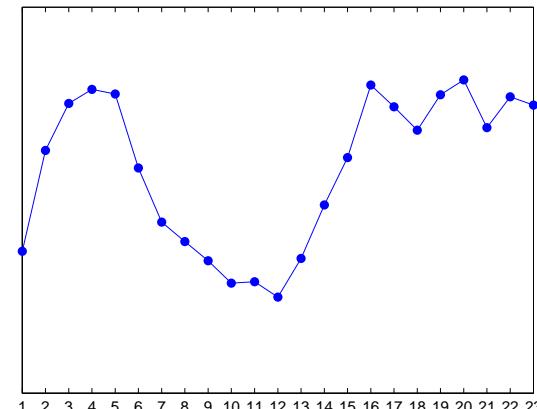
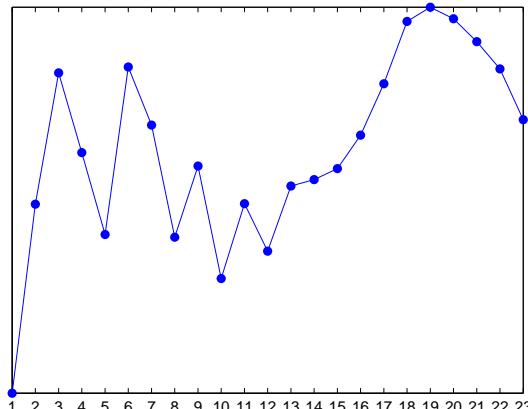
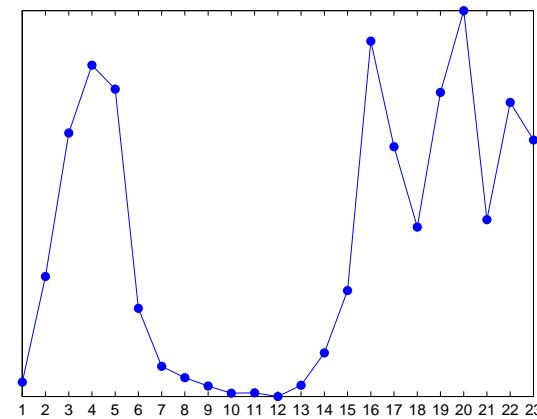
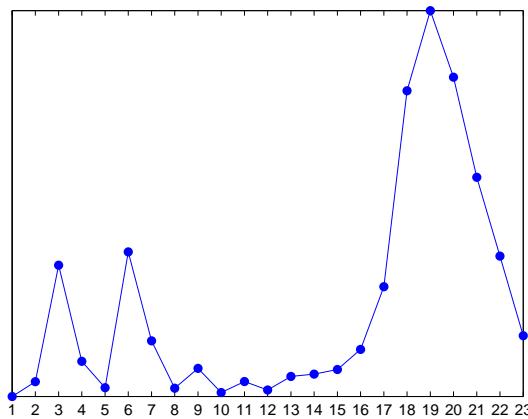
Části spekter váhujeme a integrujeme pomocí trojúhelníkových oken, které se s rostoucí frekvencí rozšiřují. Tím odstraníme jemnou strukturu spektra nesoucí informaci o nedůležitém základním tónu, aplikujeme znalost o různé schopnosti lidí rozlišovat frekvence v různé části spektra (viz `sin_100_110_1000_1010_Hz.wav`) a redukujeme počet koeficientů (z 129 na 23).



MFCC - Komprese

Výstup z banky filtrů je logaritmován.

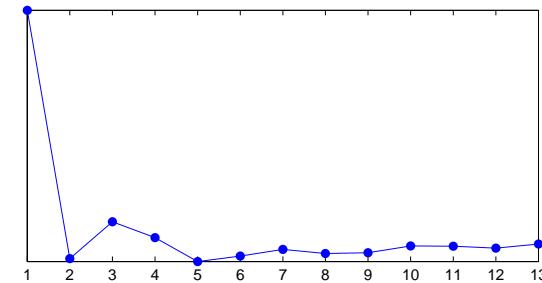
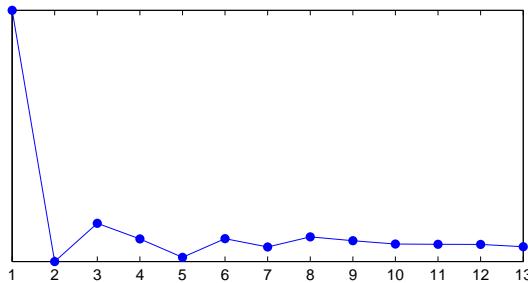
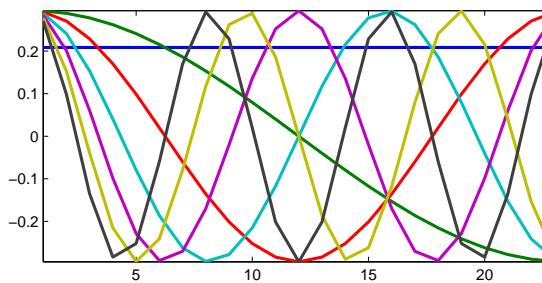
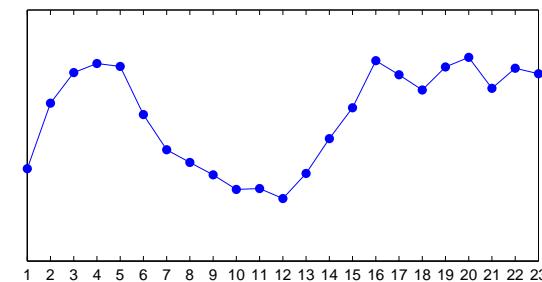
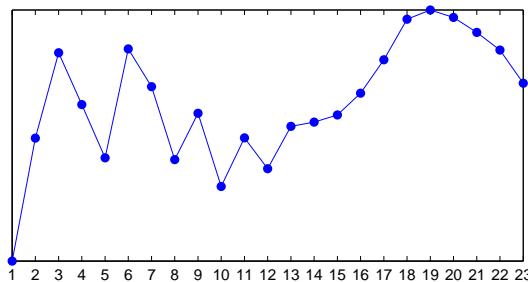
To odráží logaritmické vnímání hlasitosti lidmi
a vede na “gaussovštější” rozložení koeficientů.



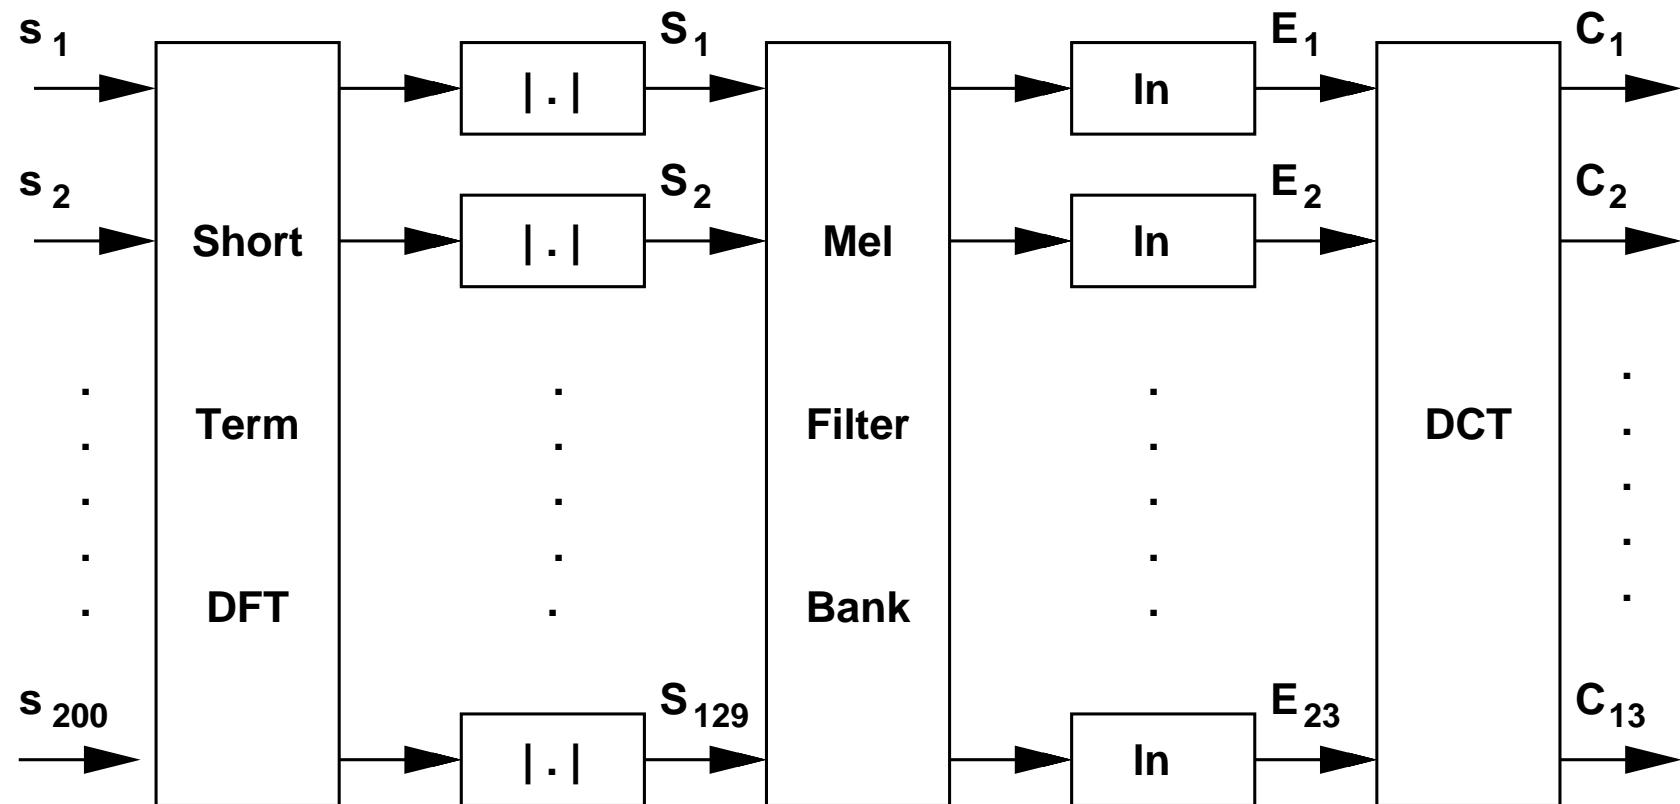
MFCC - Dekorelace

Logaritmický výstup z banky filtrů je promítнуť do cosinových bází,
čímž se jednotlivé koeficienty dekorelují.

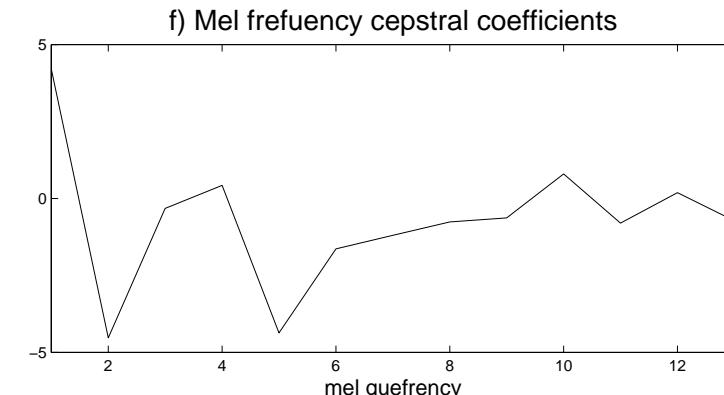
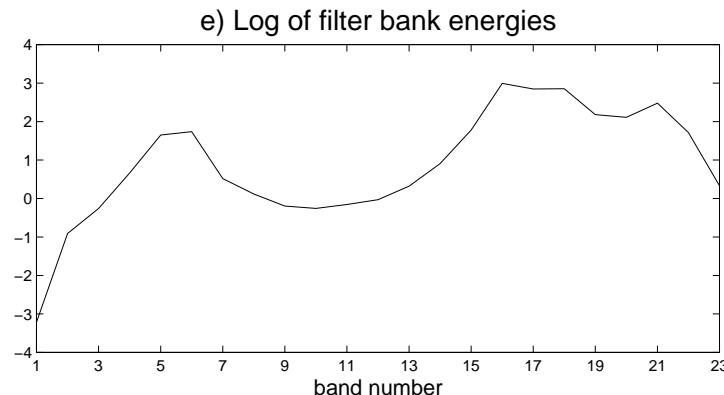
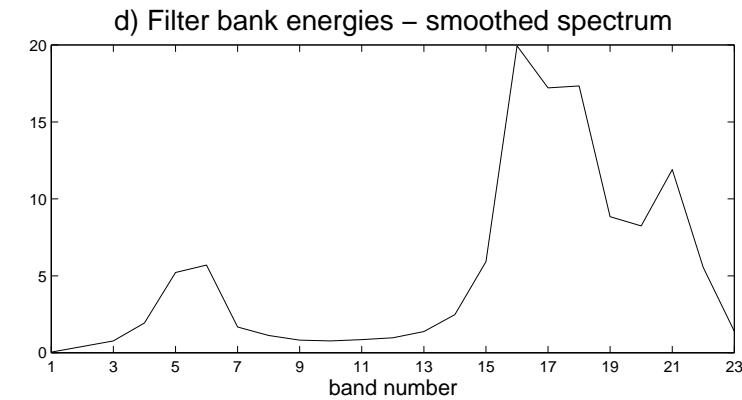
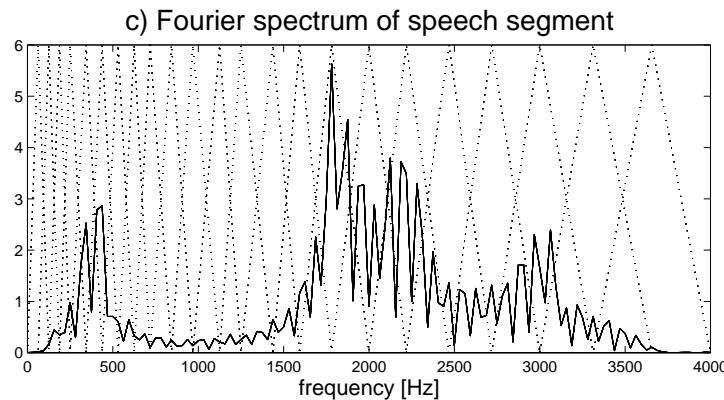
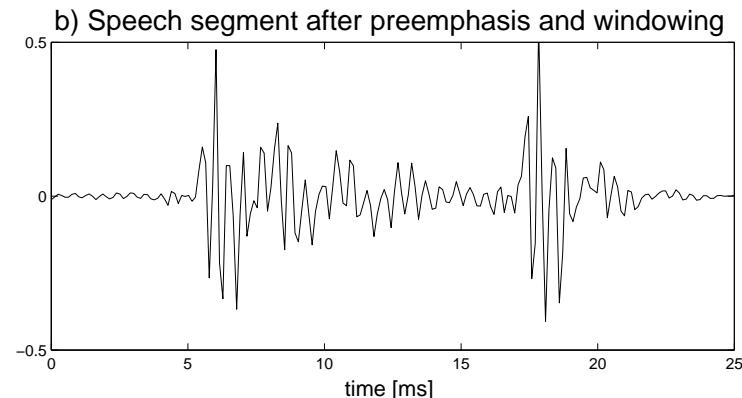
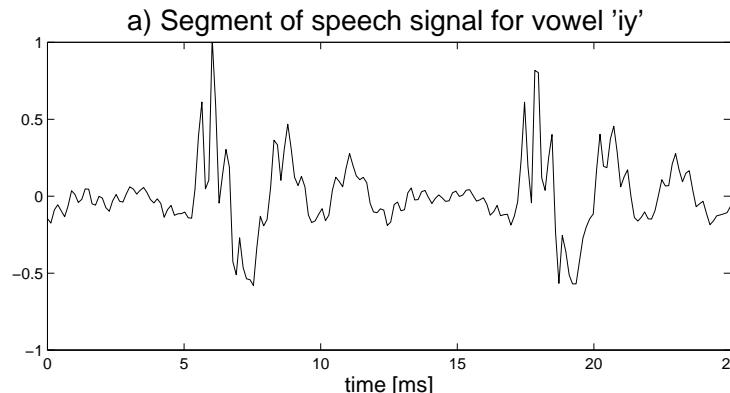
Proč? Uvidíme za chvíli



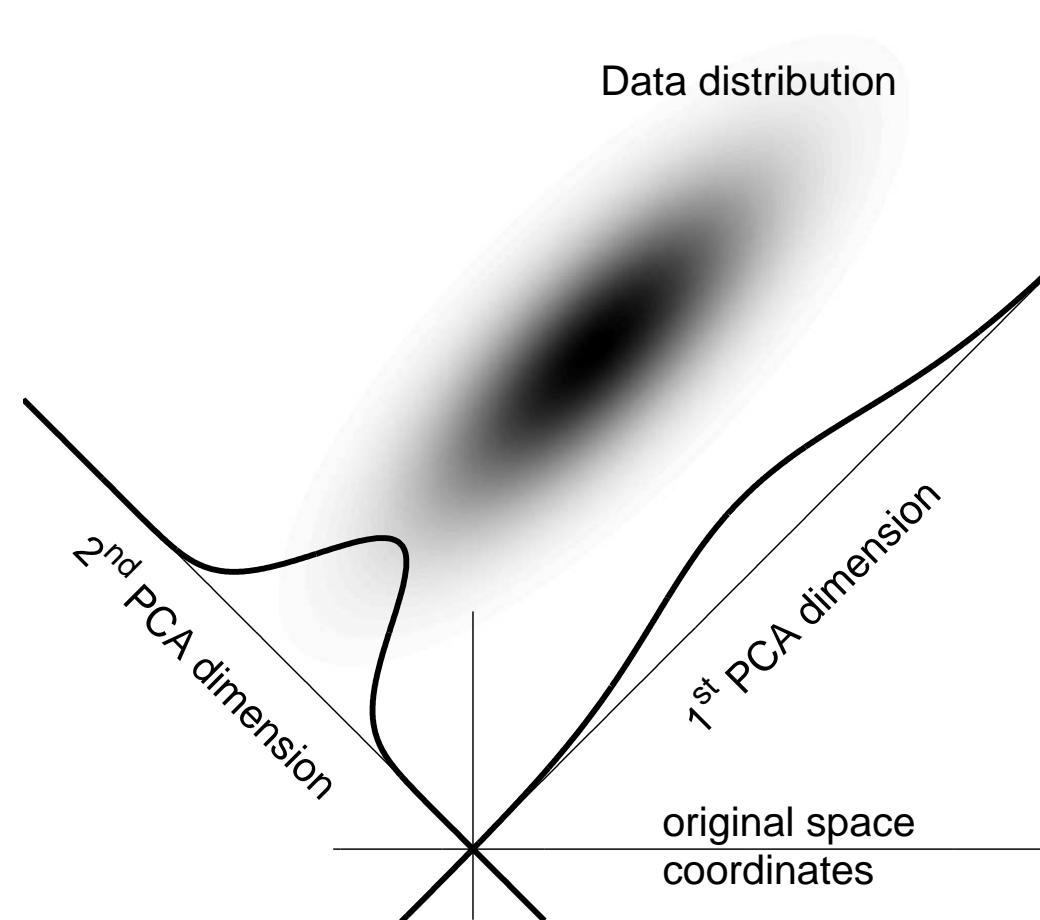
MFCC - Blokové schéma



MFCC - Jednotlivé kroky



Principal Component Analysis (PCA) neboli Karhunen-Loevyho transformace (KLT)



Principal Component Analysis (PCA)

Báze - směry PCA jsou dány vlastními vektory kovarianční matice.

Vlastní čísla udávají variance (důležitosti) v těcho směrech.

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

$$\Sigma = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T]$$

Σ - kovarianční matice

$\boldsymbol{\mu}$ - vektor středních hodnot

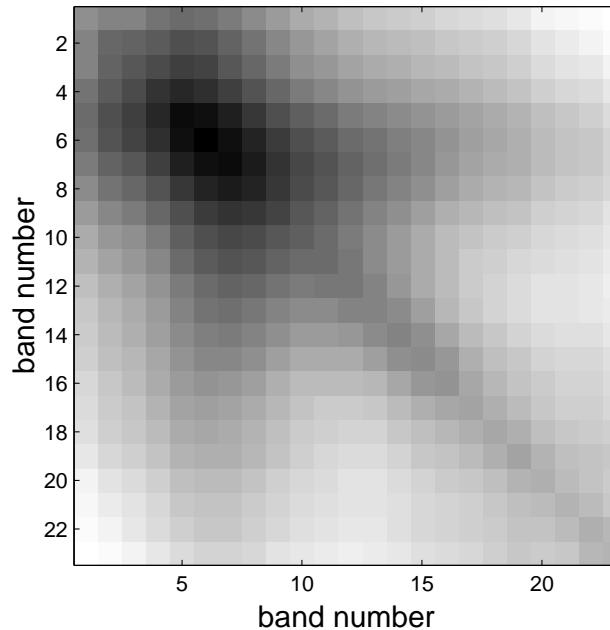
\mathbf{e}_i - vlastní vektory

λ - vlastní čísla

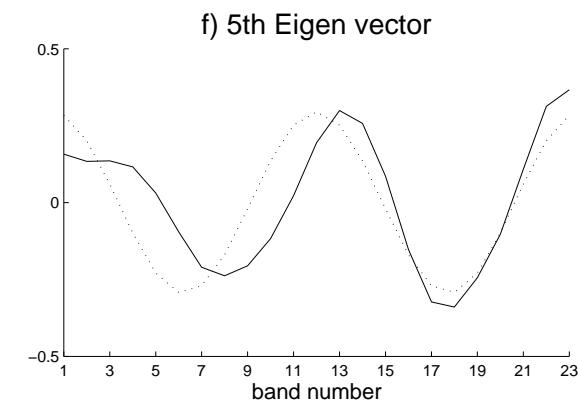
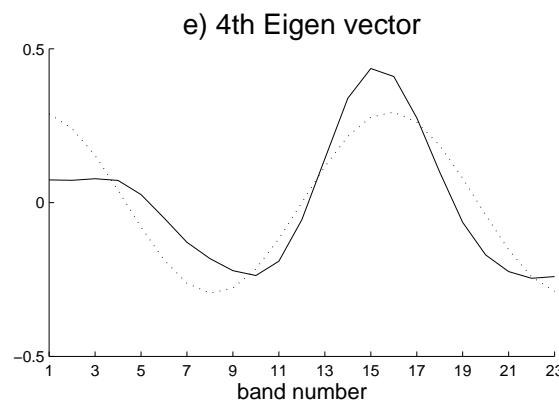
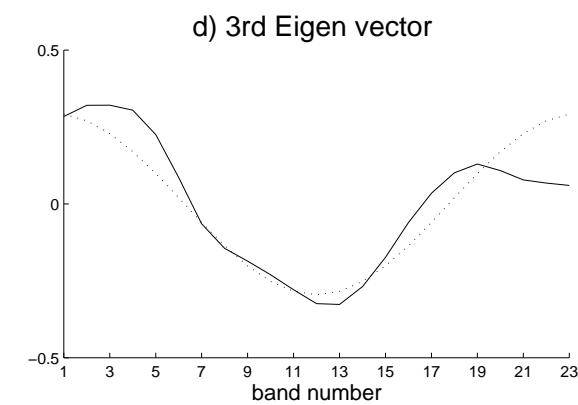
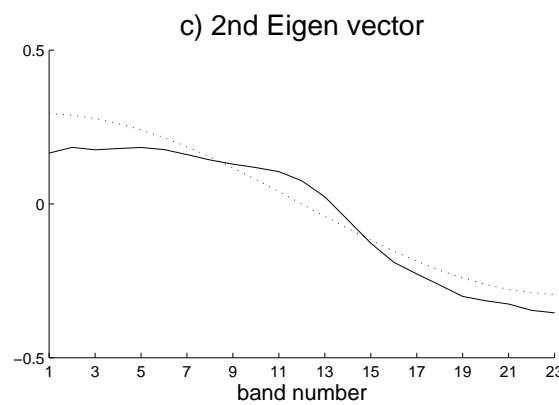
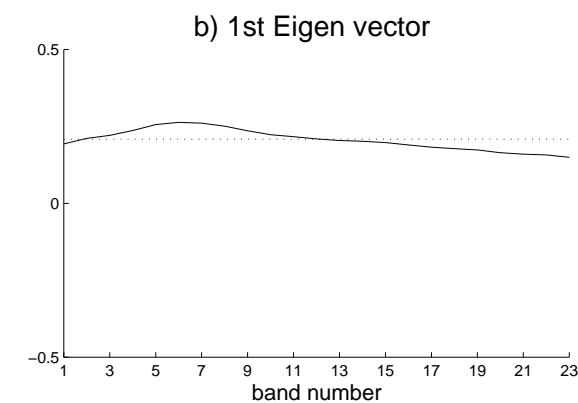
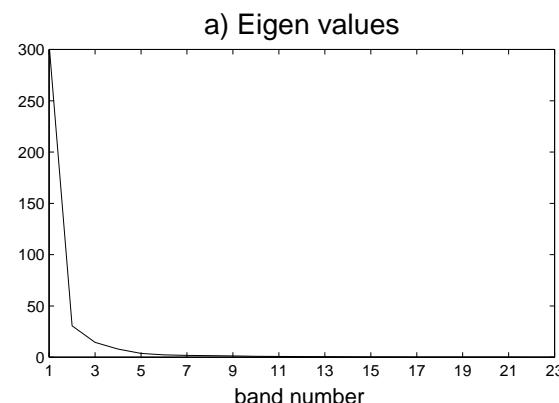
Spektrální báze odvozené pomocí PCA

Abychom u MFCC mohli nahradit DCT za “optimaln” trasformaci odvozenou pomocí PCA, odhadneme kovarianční matici pro vektory představující logaritmický výstup z banky filtrů a pro tuto kovarianční matici spočteme vlastní čísla a vlastní vektory.

Za účelem redukce dimenzí provedeme projekci pouze do nekolika vlastních vektorů (PCA bází), které odpovídají největším vlastním číslům.

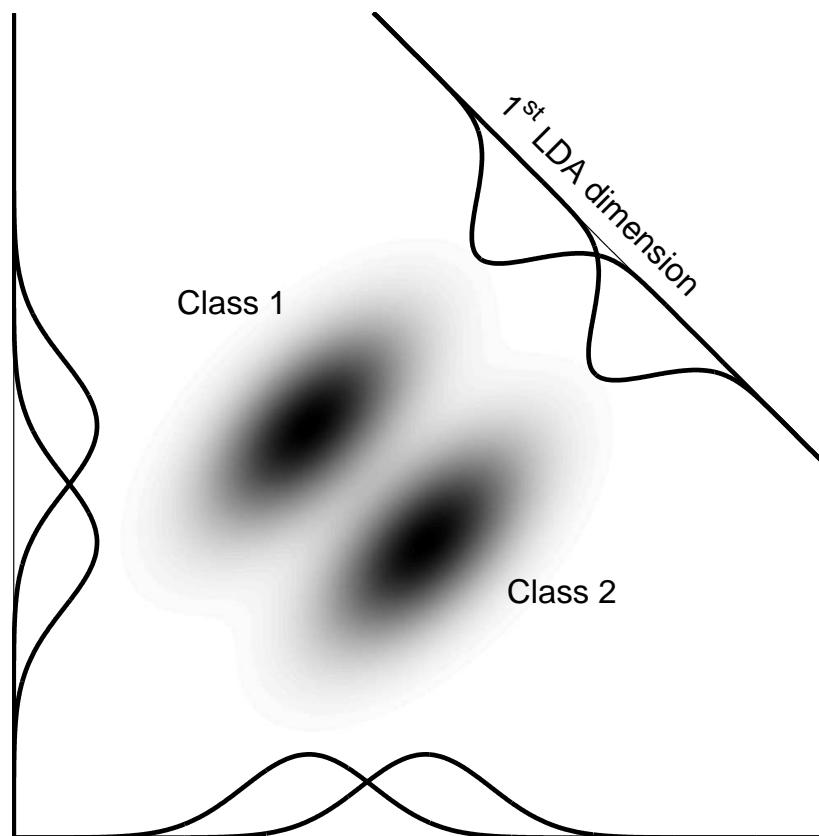


Spektrální báze odvozené pomocí PCA



Linear Discriminant Analysis (LDA)

PCA předpokládá, že důležitost směrů je dána poze variancí a počítá pouze s celkovým rozložením hustoty pravděpodobnosti. Nebere v úvahu třídy. My však potřebujeme především rozlišovat (a dekorelovat) data náležející jednotlivým třídám. Tento problém řeší LDA.



Linear Discriminant Analysis (LDA)

$$[\Sigma_{wc}^{-1} \Sigma_{ac}] \mathbf{e}_i = \lambda \mathbf{e}_i$$

$$\Sigma_{ac} = E[(\mu_p - \mu)(\mu_p - \mu)^T]$$

$$\Sigma_{wc} = E[\Sigma_p]$$

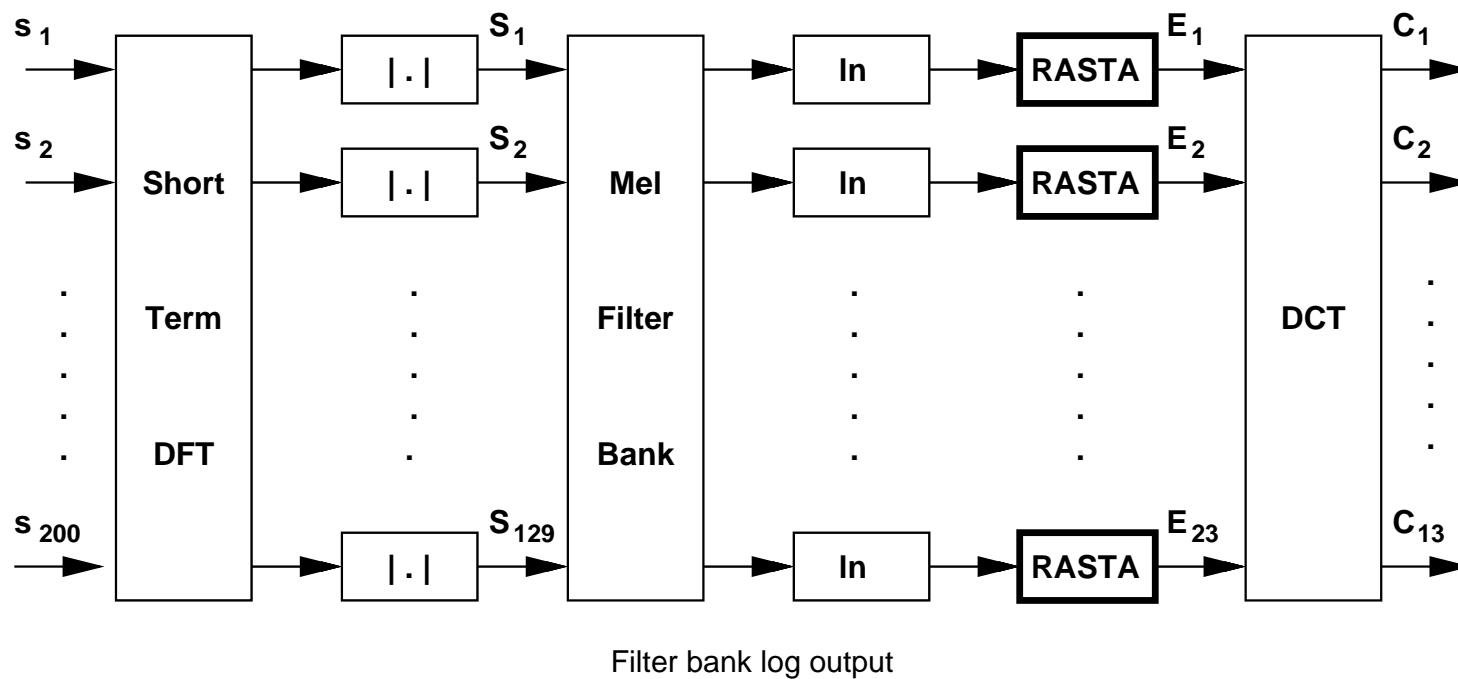
Σ_{ac}, Σ_{wc} - meziklasy a vnitrotřídní kovarianční matice

Σ_p, μ_p - kovarianční matice a střední vektor třídy p

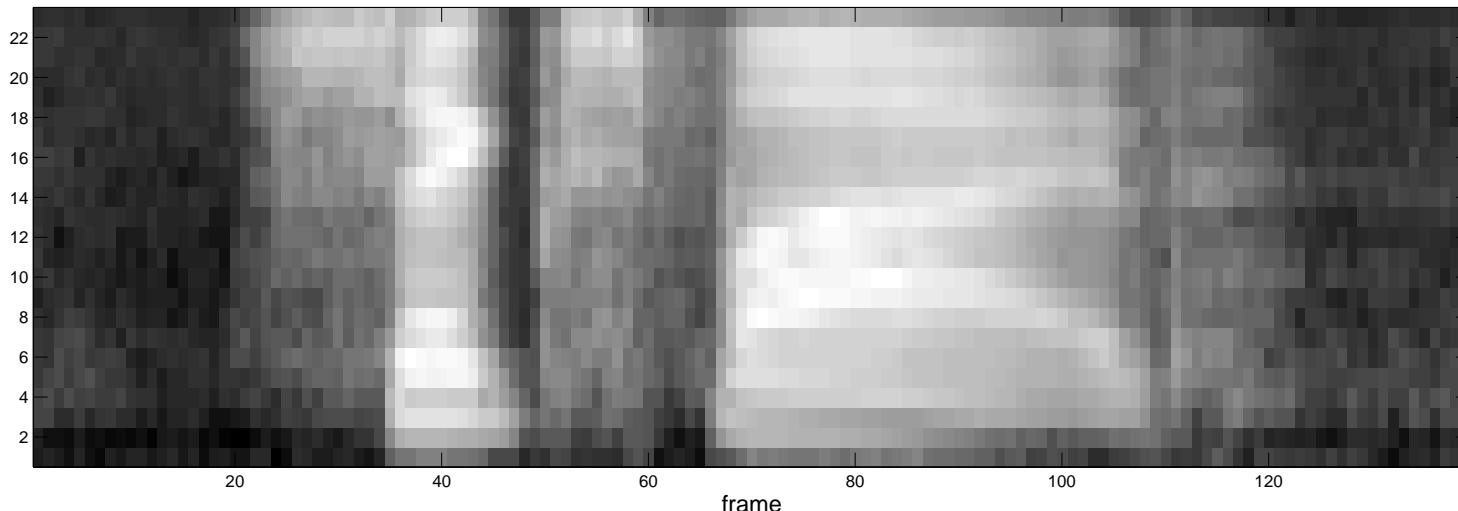
\mathbf{e}_i, λ - vlastní vektory a vlastní čísla

Nedostatek: LDA předpokládá, že všechny třídy mají stejnou kovarianční matici. Tento nedostatek řeší Heteroscedastická linearní diskriminační analýza (HLDA).

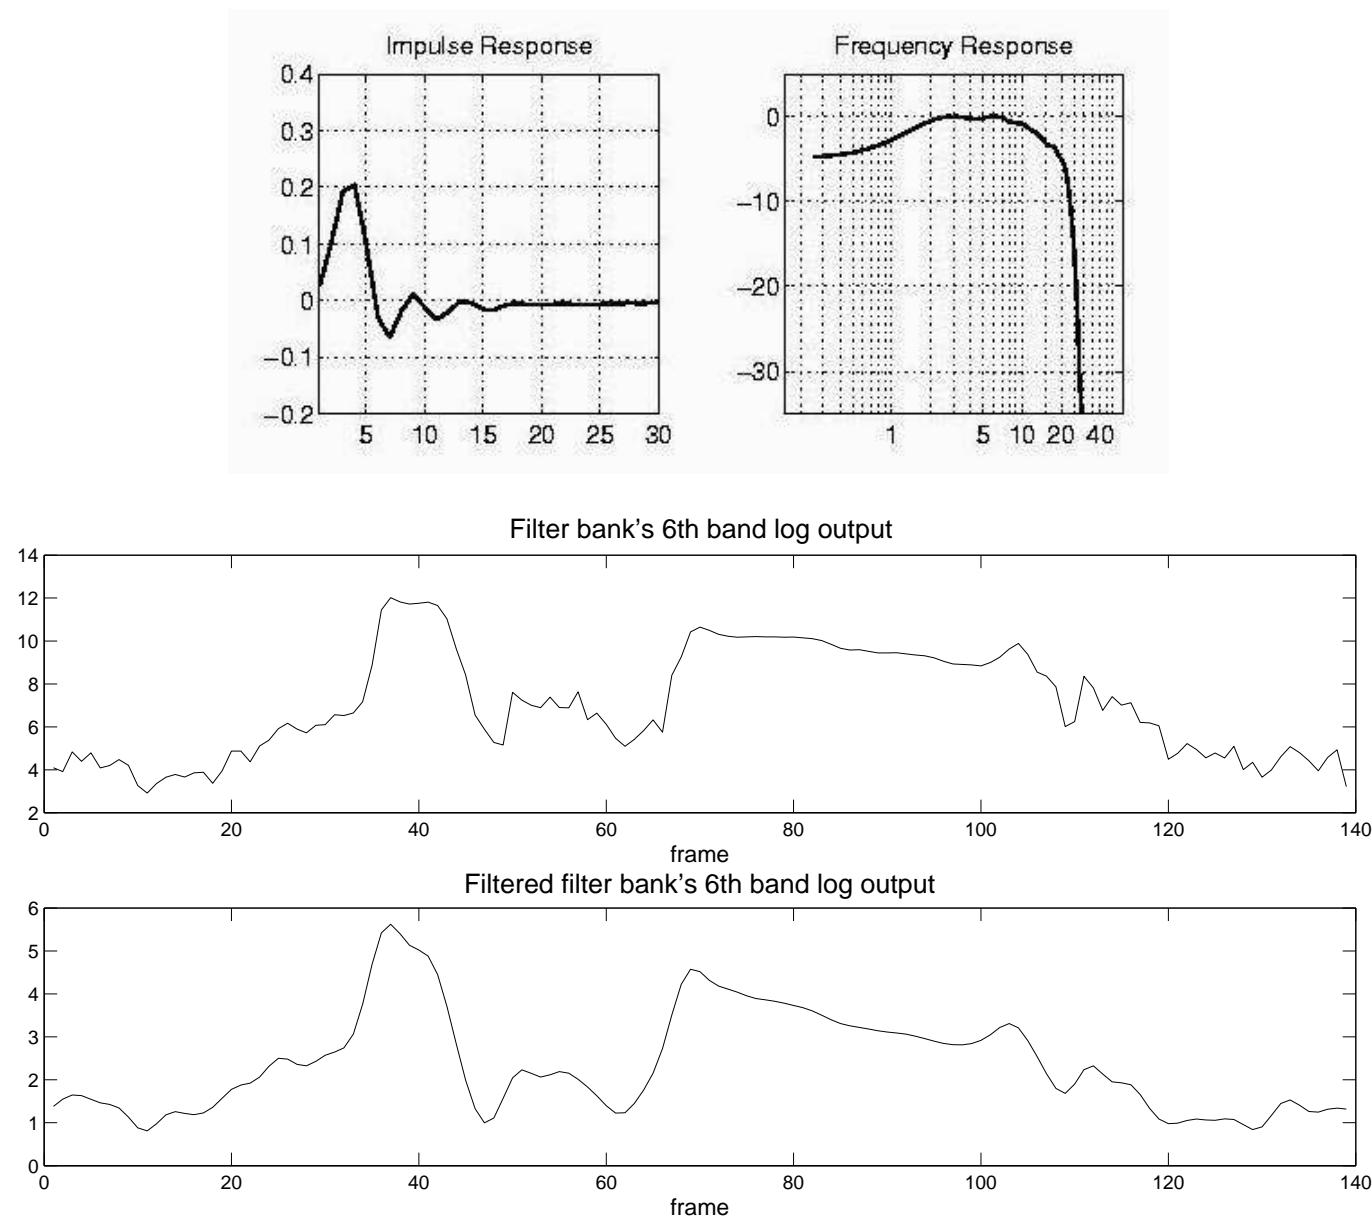
Temporální filtrace



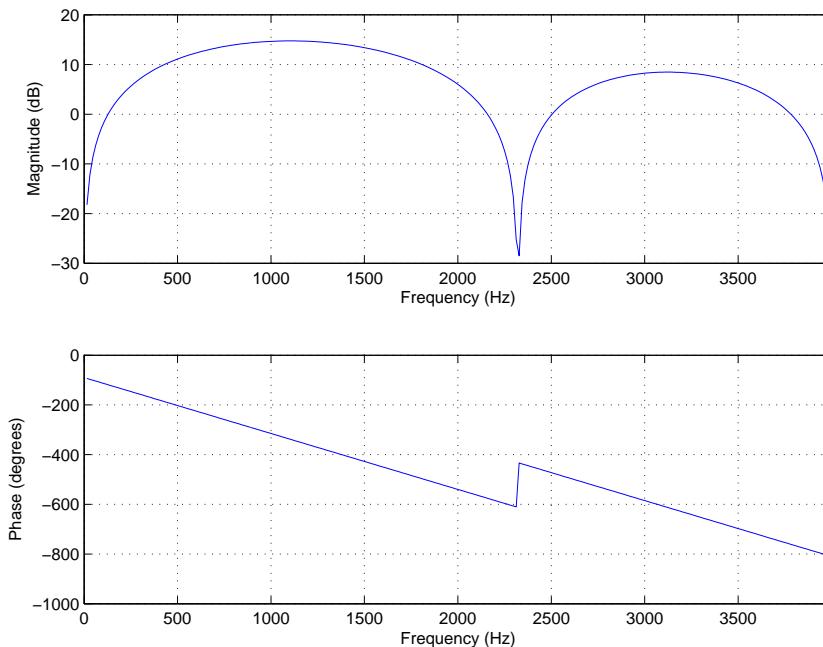
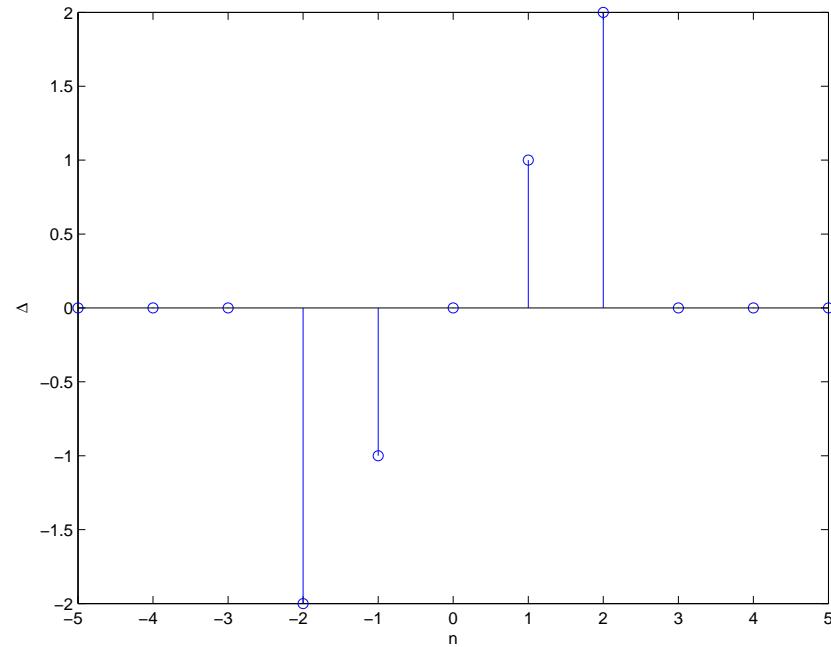
Filter bank log output



Temporální filtrace



Dynamické koeficienty



Dynamické koeficienty

