A6M33BIO - Biometrie

Biometrické metody založené na rozpoznávání hlasu II

Doc. Ing. Petr Pollák, CSc.

5. prosince 2025 - 12:17

Obsah přednášek

- **Úvod**
  - Aplikace a principy hlasové biometrické verifikace
  - Základní popis vzniku řeči (hlasu)
- **Řečové charakteristiky a příznaky pro identifikaci**
  - Základní frekvence řeči
  - Spektrální charakteristiky
  - LCP analýza
  - Formanty
  - Kepstrum, kepstrální vzdálenost
- **Reprezentace řečníka a metody srovnávání**
  - textově závislé metody - DTW
  - **textově závislé metody**
    - GMM (GMM-UBM)
    - i-vektory
    - ANN/DNN (x-vektory)
- **Příklady systémů verifikace**

Připomenutí obsahu minulé přednášky

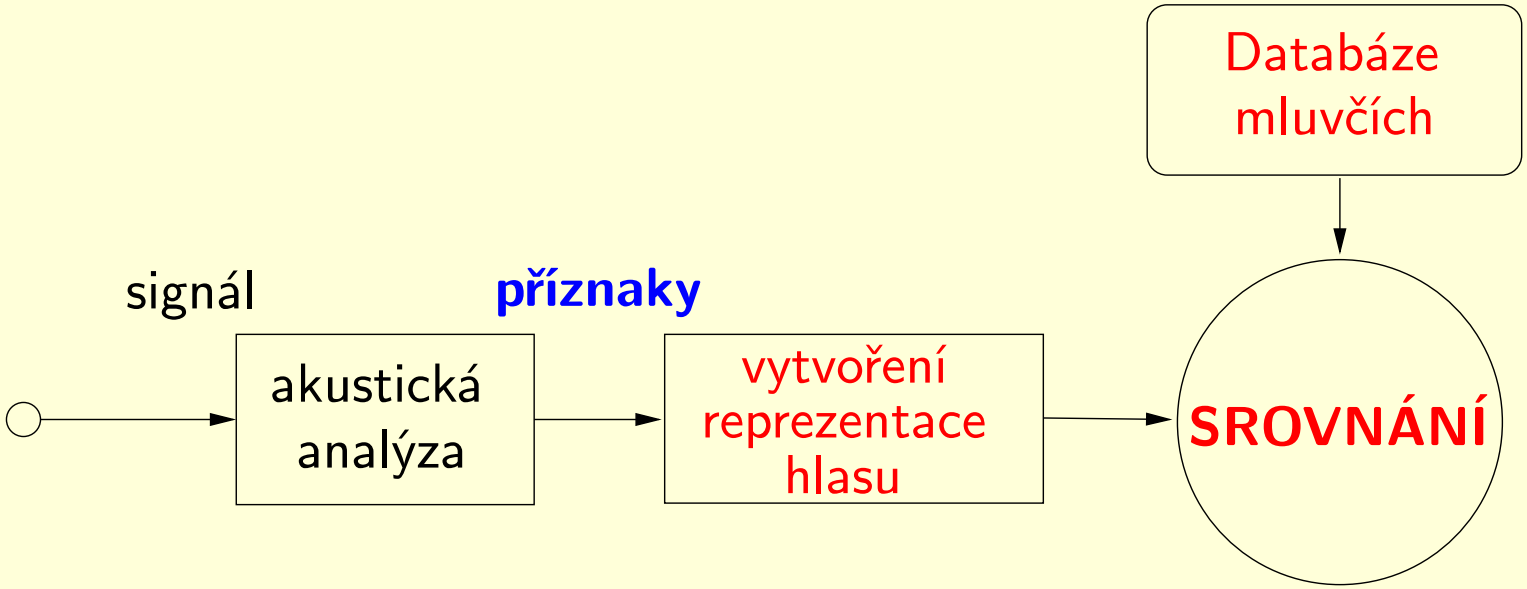

- **řečové příznaky**
  - spektrum, kepstrum, formanty, základní tón, apod.

- **reprezentace mluvčího a metody srovnání**
  - DTW, VQ, GMM, HMM, **i-vektory**, ANN/**DNN** (**x-vektory**)

I. část

Textově závislé metody hlasové identifikace

Rozpoznávání řečníka na základě časových funkcí

Možné časové funkce

- vzorová promluva
- průběh energie - rytmizace promluvy
- průběh f_o - intonace v promluvě
- časová závislost vybraného formantu (speciální příznaky)

Klasifikace na bázi DTW :

- srovnání časových funkcí (sekvencí příznaků) různé délky

$$\boldsymbol{O} = [\boldsymbol{o}_1, \boldsymbol{o}_2, \ldots, \boldsymbol{o}_N] \qquad \text{vs.} \qquad \boldsymbol{O}^{ref} = [\boldsymbol{o}_1^{ref}, \boldsymbol{o}_2^{ref}, \ldots, \boldsymbol{o}_M^{ref}])$$

- Vzdálenost (kepstrální) mezi všemi body (segmenty p příznaků):

$$d_{i,j} = \sum_{k=1}^{p} (o_i[k] - o_j^{ref}[k])^2 \quad \text{pro } i = 1, \ldots, N\,;\, j = 1, \ldots, M$$

- Kumulovaná vzdálenost algoritmem dynamického programování:

$$dk_{i,j} = \min\left(dk_{i-1,j} + d_{i,j}, dk_{i,j-1} + d_{i,j}, dk_{i-1,j-1} + d_{i,j}\right)$$
$$\text{pro } i = 1, \ldots, N\,;\, j = 1, \ldots, M$$

- skóre pro SRE - normalizovaná finální kumulovaná DTW vzdálenost

$$score_{dtw} = \frac{dk_{N,M}}{NM}$$

DTW - shrnující popis metody

Referenční promluva délky N

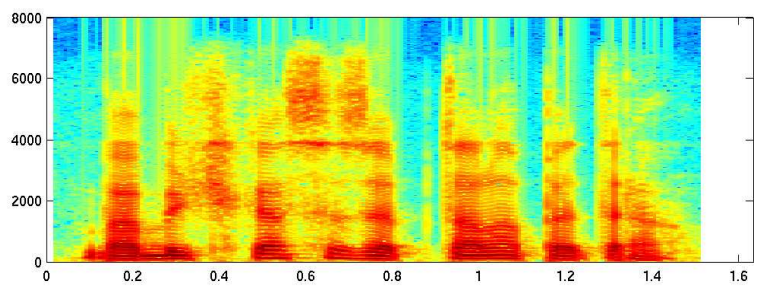

Rozpoznávaná promluva délky M

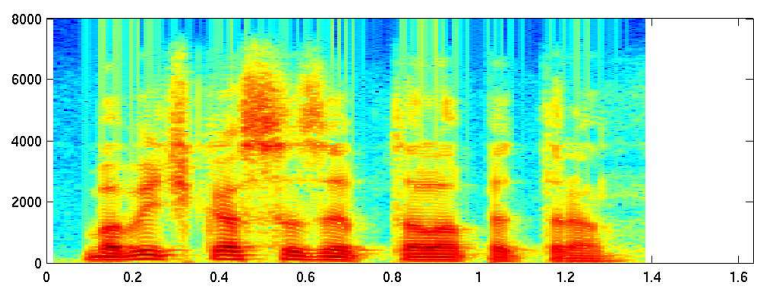

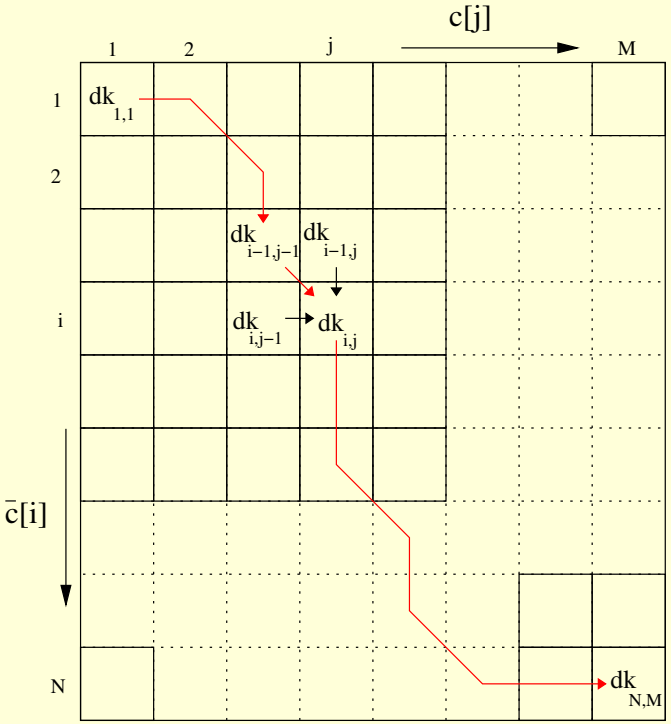

Finální skóre - možná fůze pro více dílčích příznaků (speciální příznaky)

- vážený součet dílčích klasifikací
- často poloautomatická expertní identifikace (forenzní praxe)

VÝHODY:

- jednoduchá koncepce, potřeba málo dat

NEVÝHODY:

- hodně malé rozdíly ve skóre pro některé typy časových funkcí
- **konkrétní časová funkce** → **textově závislá metoda**

Příznaky pro textově nezávislé rozpoznávání mluvčího

Principiální obsah :

- typický spektrální obsah pro libovolnou promluvu mluvčího
  tj. spektrum v libovolném čase $\rightarrow$ obecné rozložení spektra
  (popisuje parametry vokálního traktu, tj. barvu hlasu)
- potlačení reduntatní informace / redukce dimenze příznaků
  $\rightarrow$ banka filtrů, kepstrum
- typické časové změny ve spektrálním obsahu
  $\rightarrow$ zahrnutí kontextové informace
  (popisuje změny nastavení vokálního traktu, tj. styl řeči)

Používané příznaky pro textově nezávislé SRE:

- MFCC kepstrum (používané příznaky pro GMM, i-vektory)
  - často vyšší dimenze ≥ 20
  - kontext na bázi delta parametrů (především 1. derivace)
- výstup banky filtrů (vyhlazený redukovaný spektrogram)
  - používané často pro systémy na bázi DNN - x-vektory
  - kontext na bázi řetězení segmentů
- celý spektrogram v plném rozlišení (End-to-End systém)
  - pro některé struktury neuronových sítí (CNN)

Rozložení kepstra ($c[2]$ vs. $c[3]$) - řečník 1 & 2 & 3 & 4

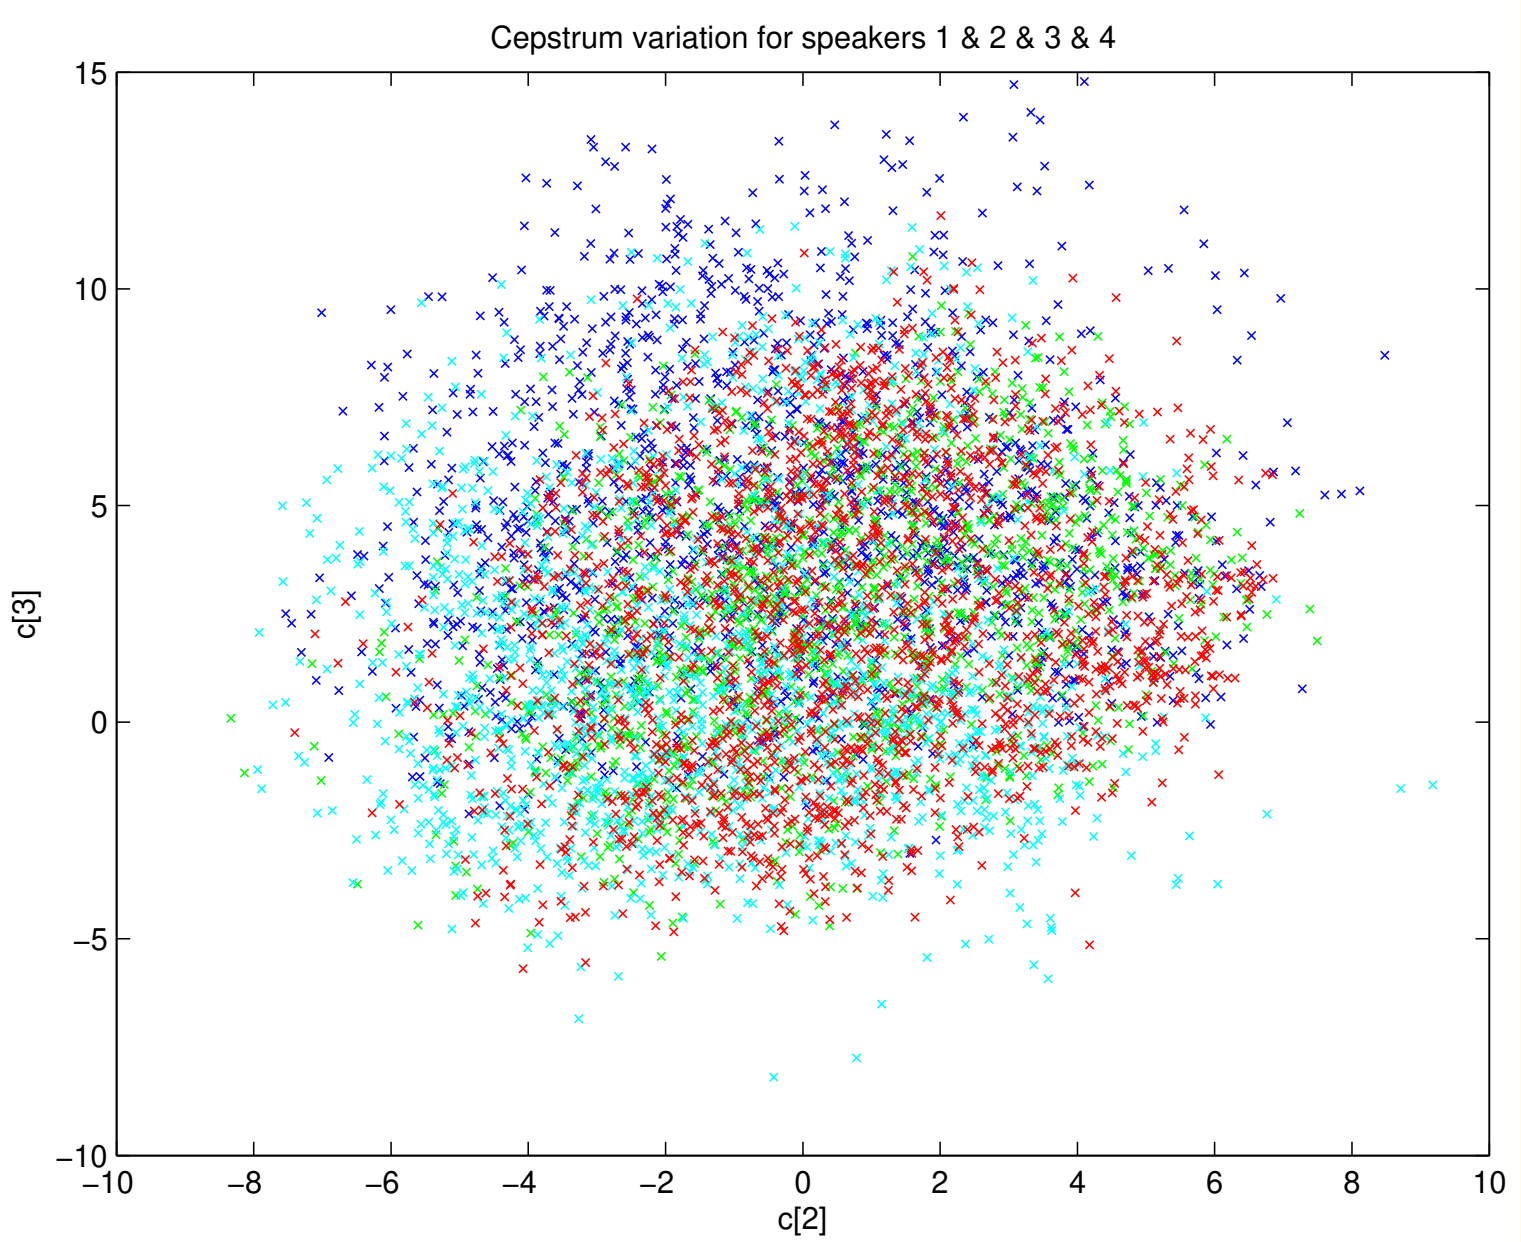

II. část

Textově nezávislá verifikace/identifikace na bázi GMM

Rozpoznávání řečníka na bázi GMM

Statistika rozložení kepstra - **GMM** (Gaussian Mixture Model)

$$p(\mathbf{o}|\lambda^{spk}) = \sum_{i=1}^{M_s} c_i^{spk} \cdot \mathcal{N}\left(\mathbf{o},\, \boldsymbol{\mu}_i^{spk},\, \mathbf{C}_i^{spk}\right)$$

- $\mathcal{N}(\mathbf{o},\, \boldsymbol{\mu},\, \mathbf{C})$ ... N-rozměrná gaussovská funkce daná vektorem středních hodnot $\boldsymbol{\mu}$ a kovarianční maticí $\mathbf{C}$ pro příznakový vektor $\mathbf{o}$

- λ^s ... GMM model pro řečníka *spk* s parametry:
  $\boldsymbol{\mu}_i^{spk}$ ... střední hodnota i-té složky
  $\mathbf{C}_i^{spk}$ ... kovarinační matice i-té složky
  c_i^{spk} ... váha i-té složky

- odstranění neřečových segmentů, VAD (Voice Activity Detector)

- více směsí modeluje variabilitu příznaků pro daného řečníka

- typické počty směsí: 8-512, 512+ pro UBM
  (počty směsí zavisí na množství trénovacích dat)

- *pouze střední hodnoty = VQ, kmeans, kódová kniha*

Rozložení prvků kódové knihy kepstra mluvčího A

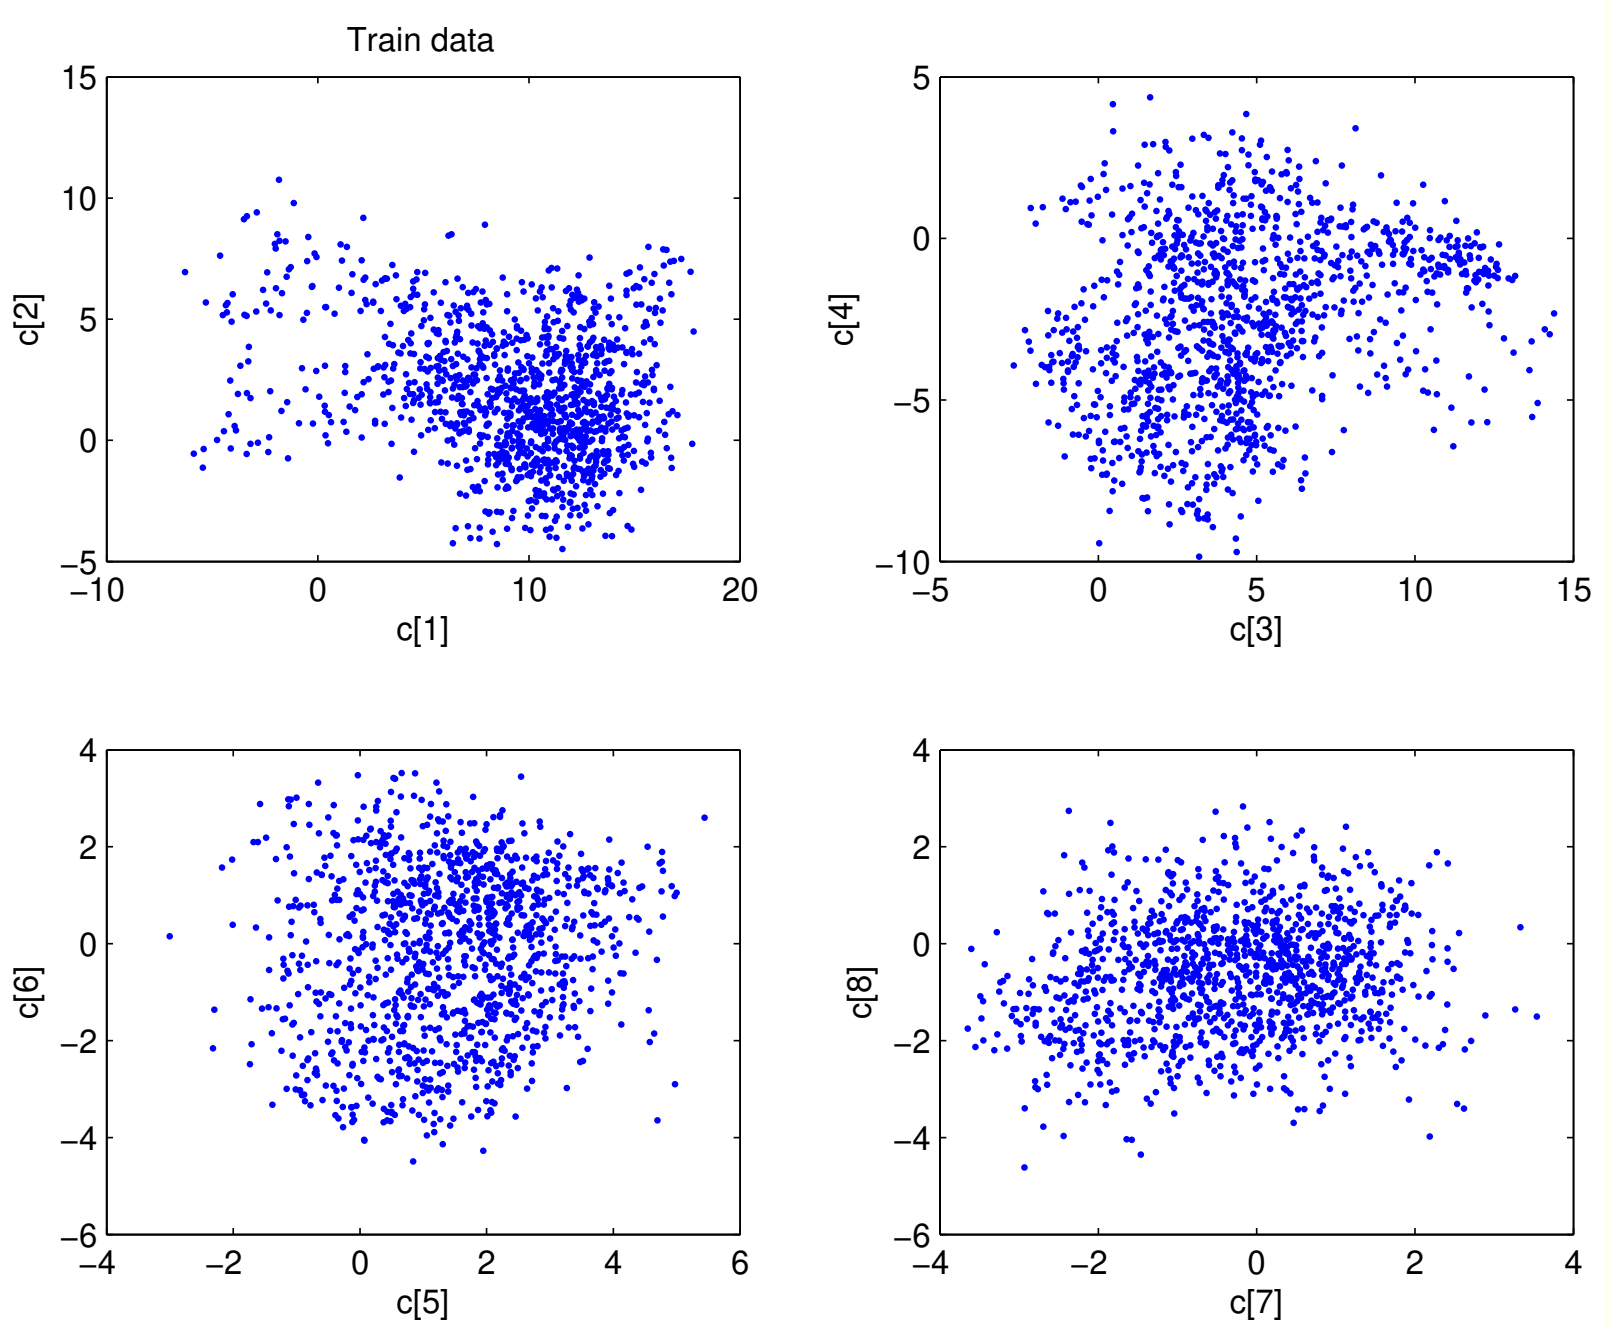

Rozložení prvků kódové knihy kepstra mluvčího B

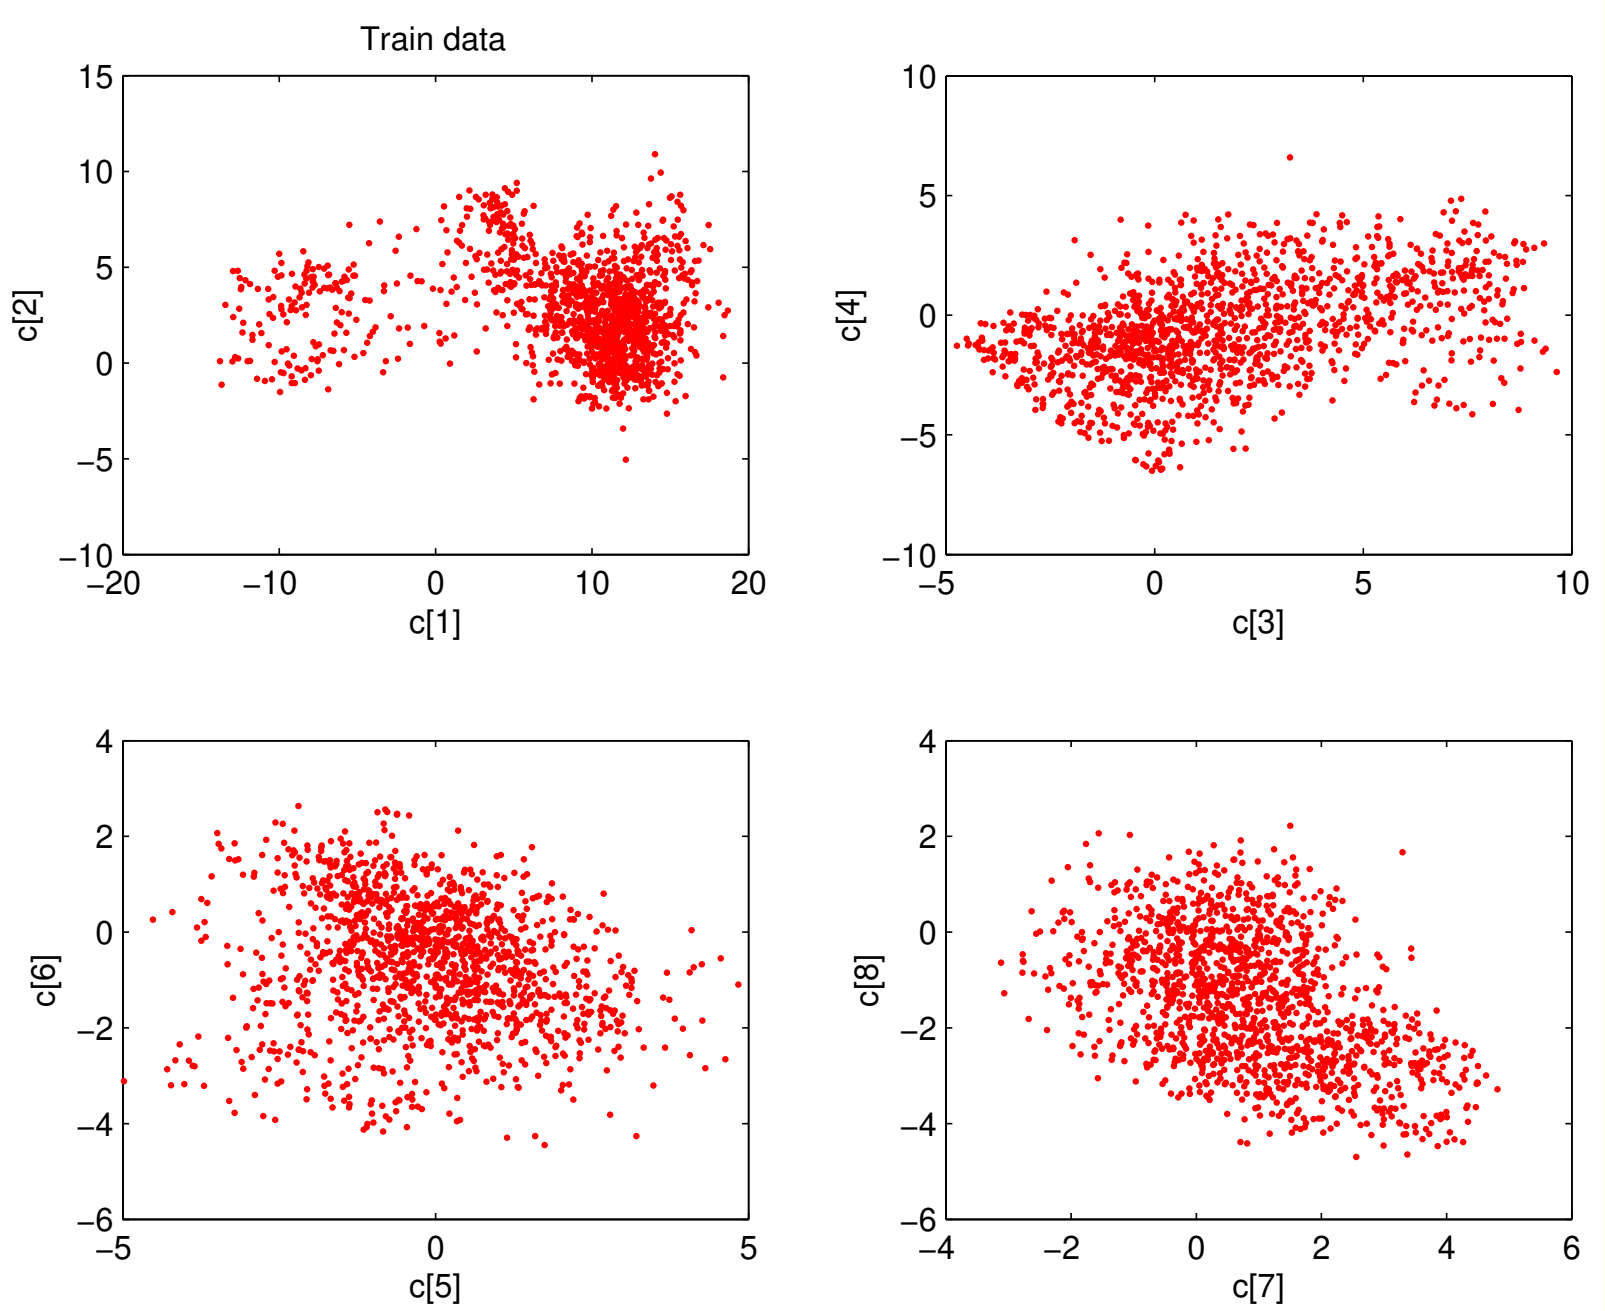

GMM model rozložení kepstra mluvčího A

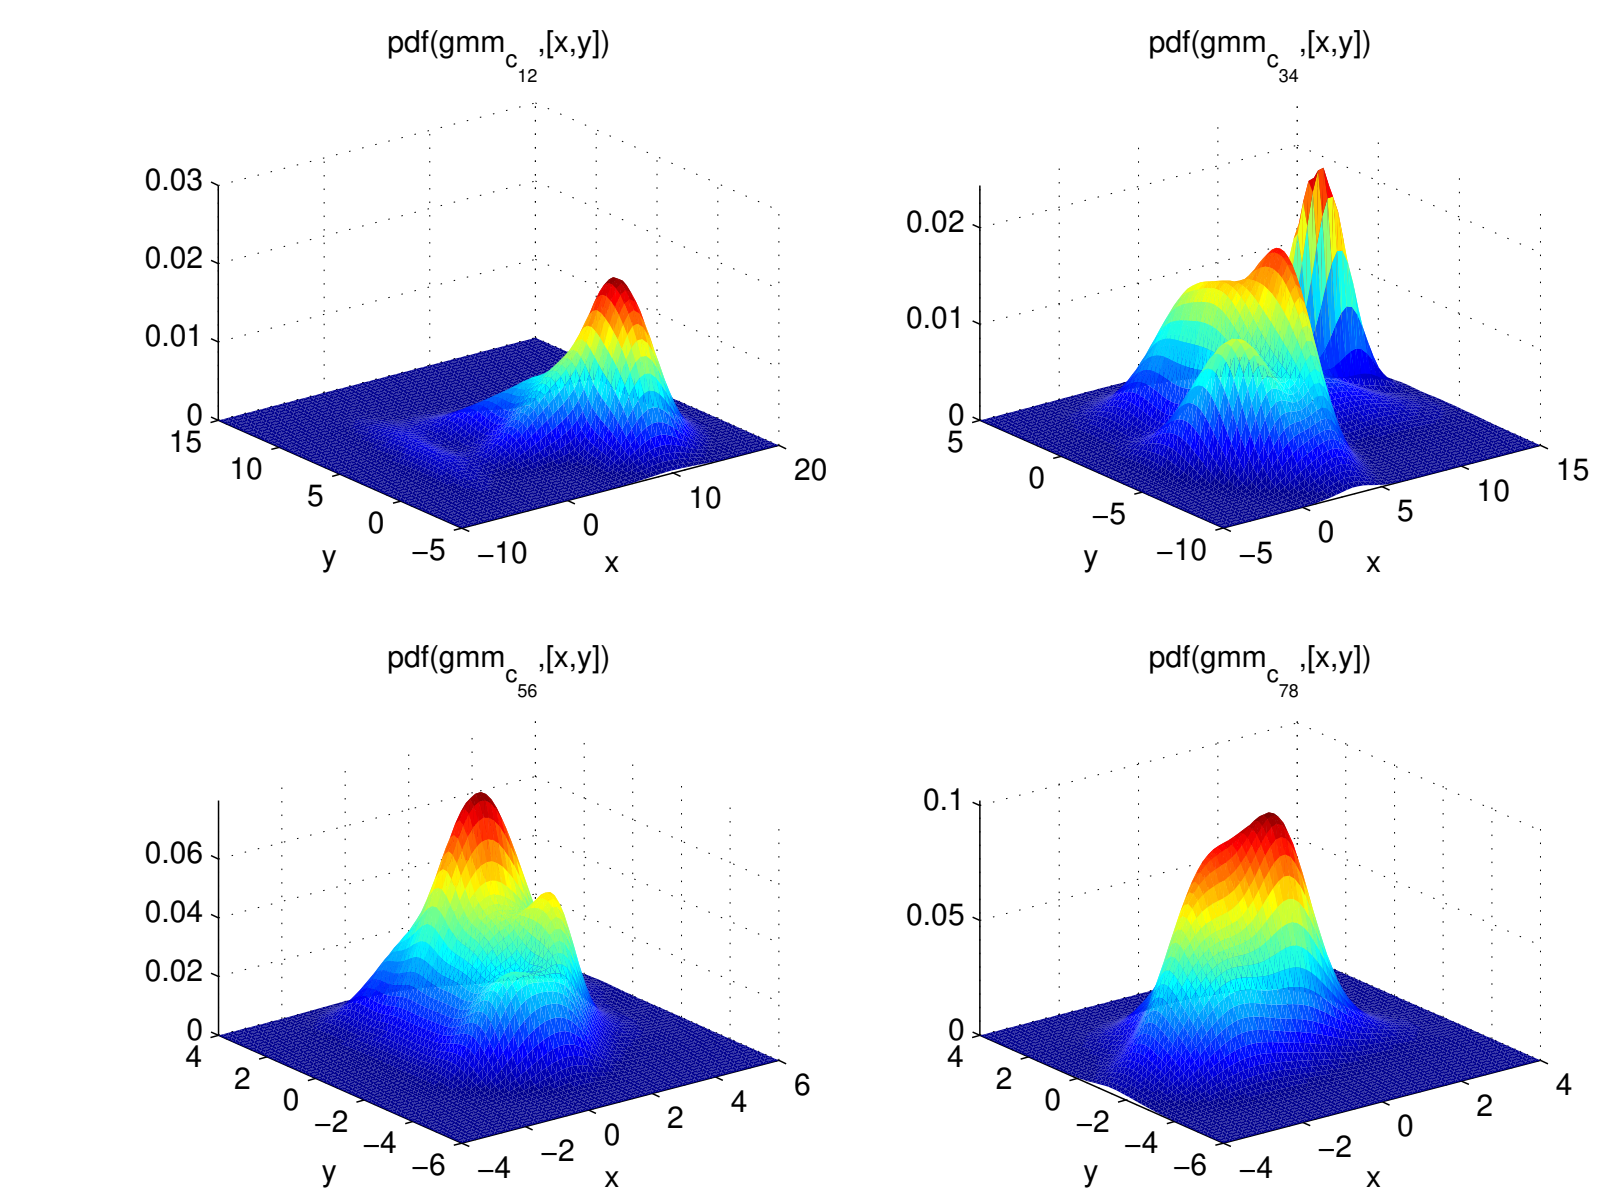

GMM model rozložení kepstra mluvčího B

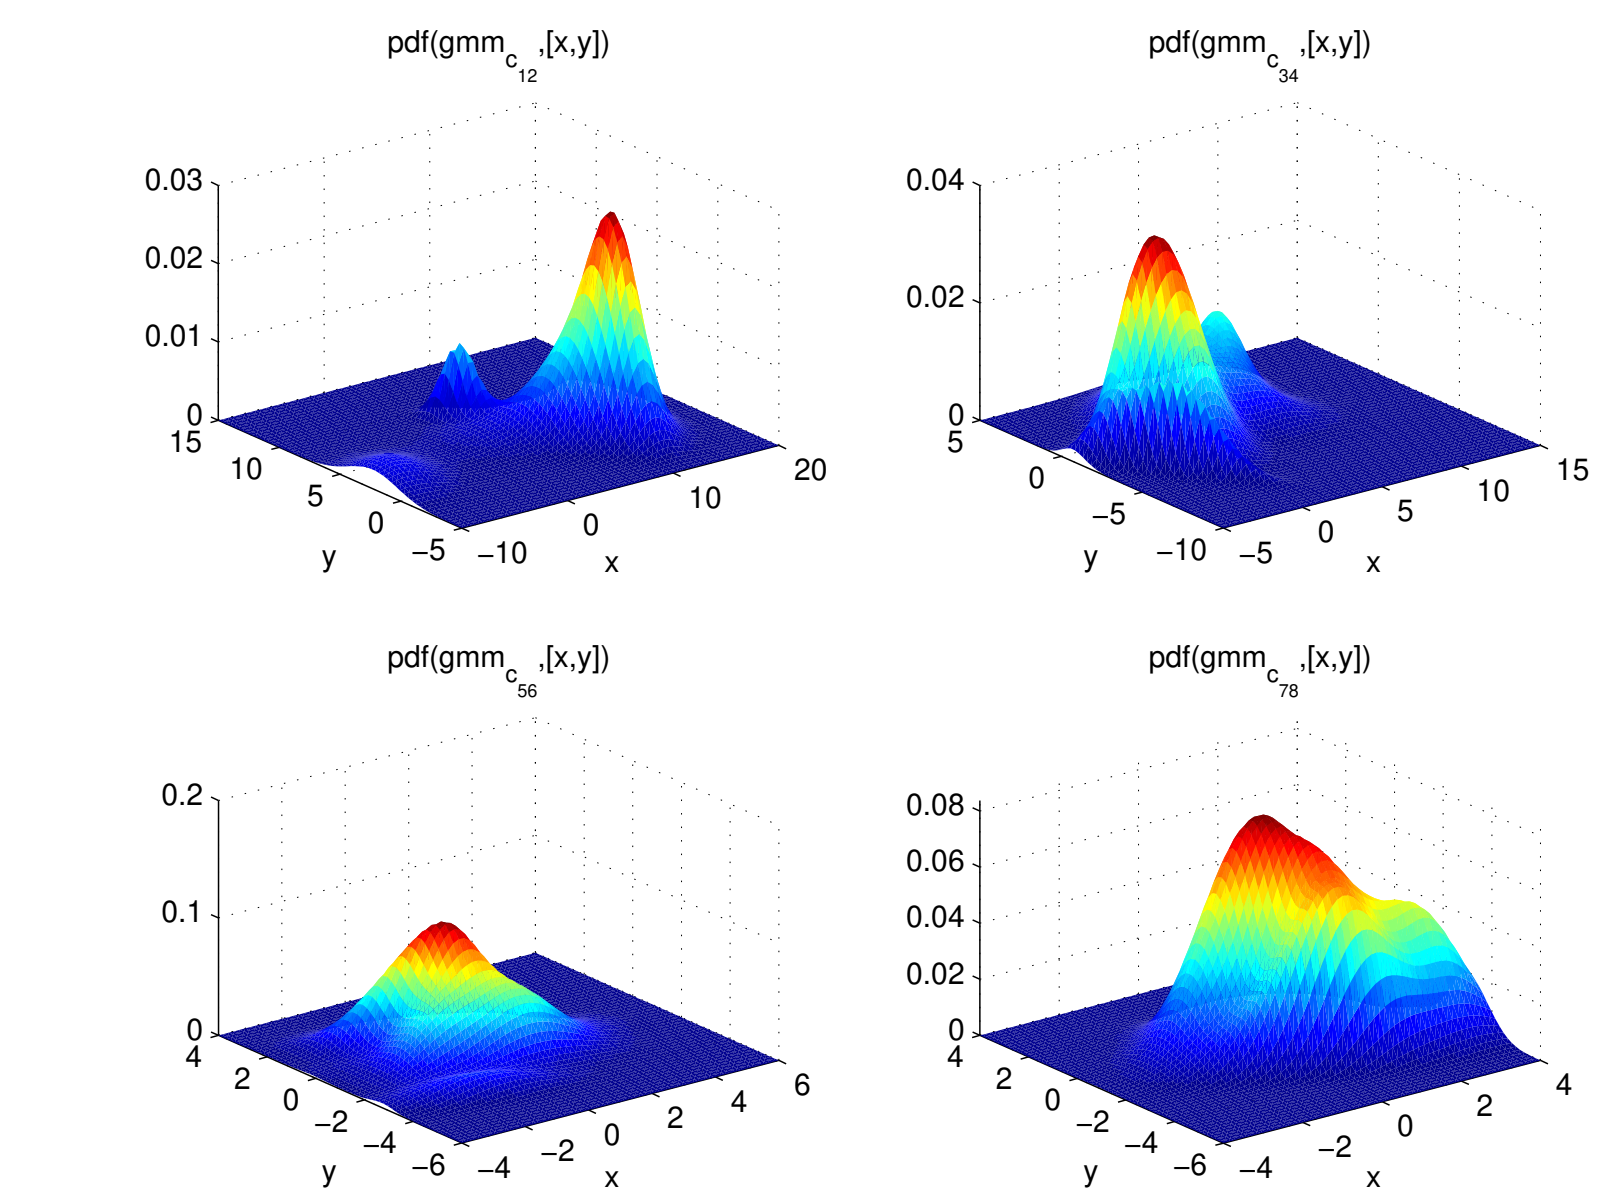

Klasifikace na bázi GMM

Klasifikační míra : věrohodnost příznaku pro daný model

Věrohodnost se počítá z celé promluvy $\mathbf{O} = (\mathbf{o_1}, \mathbf{o_2}, ..., \mathbf{o_n})$

- pro všechny krátkodobého segmenty promluvy
- je třeba vypustit neřečové segmenty (aplikace VAD)

$$P(\mathbf{O}|\lambda^s) = \prod_{j=1}^{N} p(\mathbf{o_j}|\lambda^s)$$

Logaritmická věrohodnost - součet logaritmů emitovaných pravděpodobností pro všechny krátkodobé realizace

(omezení možnosti podtečení)

$$\log P(\mathbf{O}|\lambda^s) = \sum_{j=1}^{N} \log p(\mathbf{o_j}|\lambda^s)$$

Normovaná logaritmická věrohodnost na délku signálu

- průměrování emitovaných log. pravděpodobností

$$\log P(\mathbf{O}|\lambda^s) = \frac{1}{N} \sum_{j=1}^{N} \log p(\mathbf{o_j}|\lambda^s)$$

Výpočet skóre pro 2 řečníky

Logaritmické pravděpodobnosti pro všechny krátkodobé segmenty

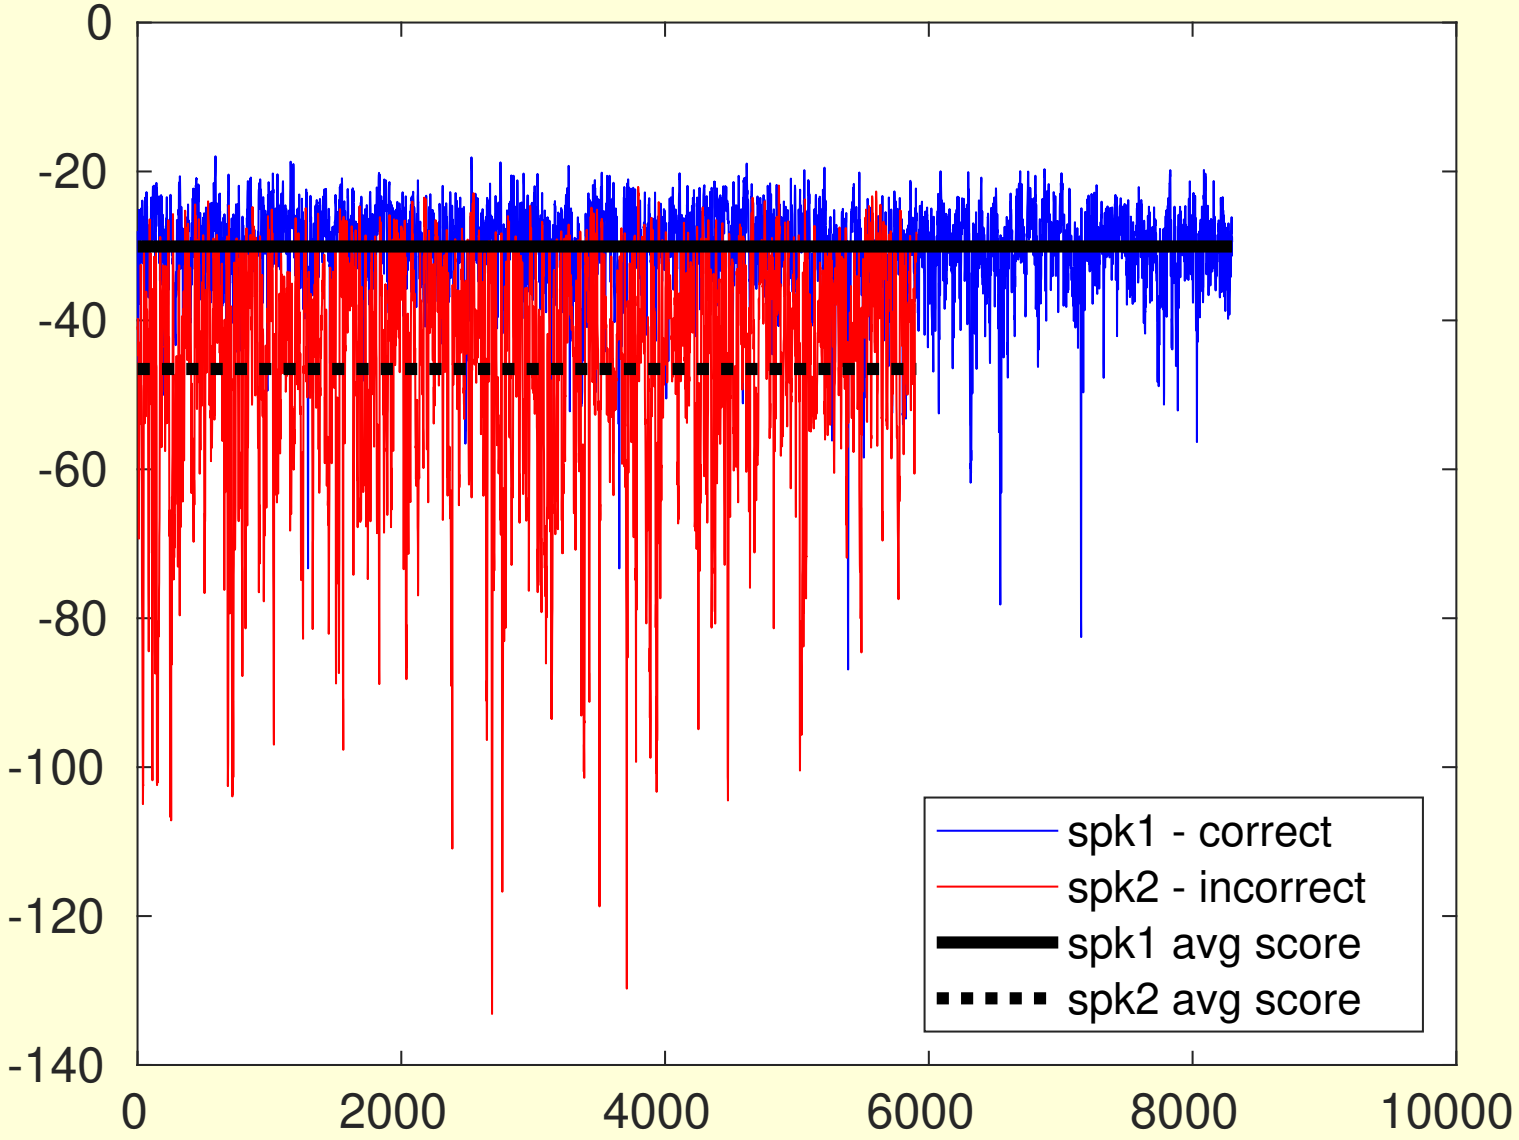

Verifikace - nastavení prahu

Příklad volby verifikačního prahu

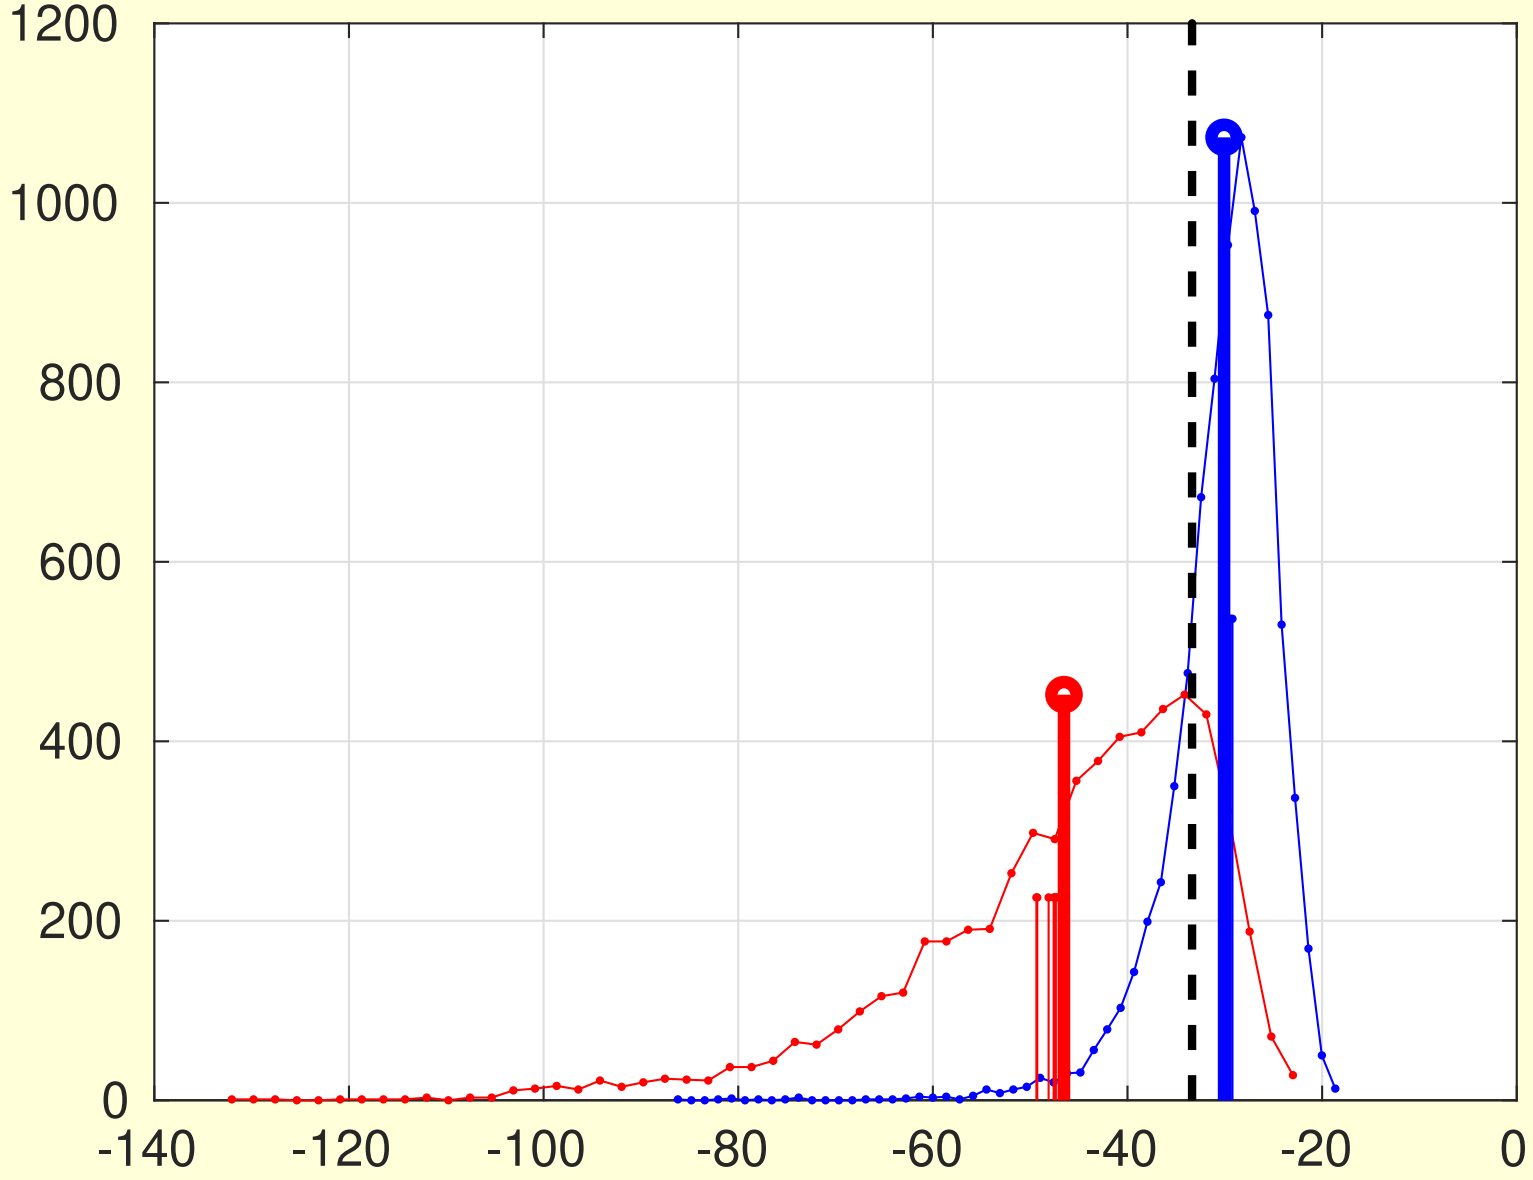

Statistiky výsledků pro 4 řečníky a 1 GMM model

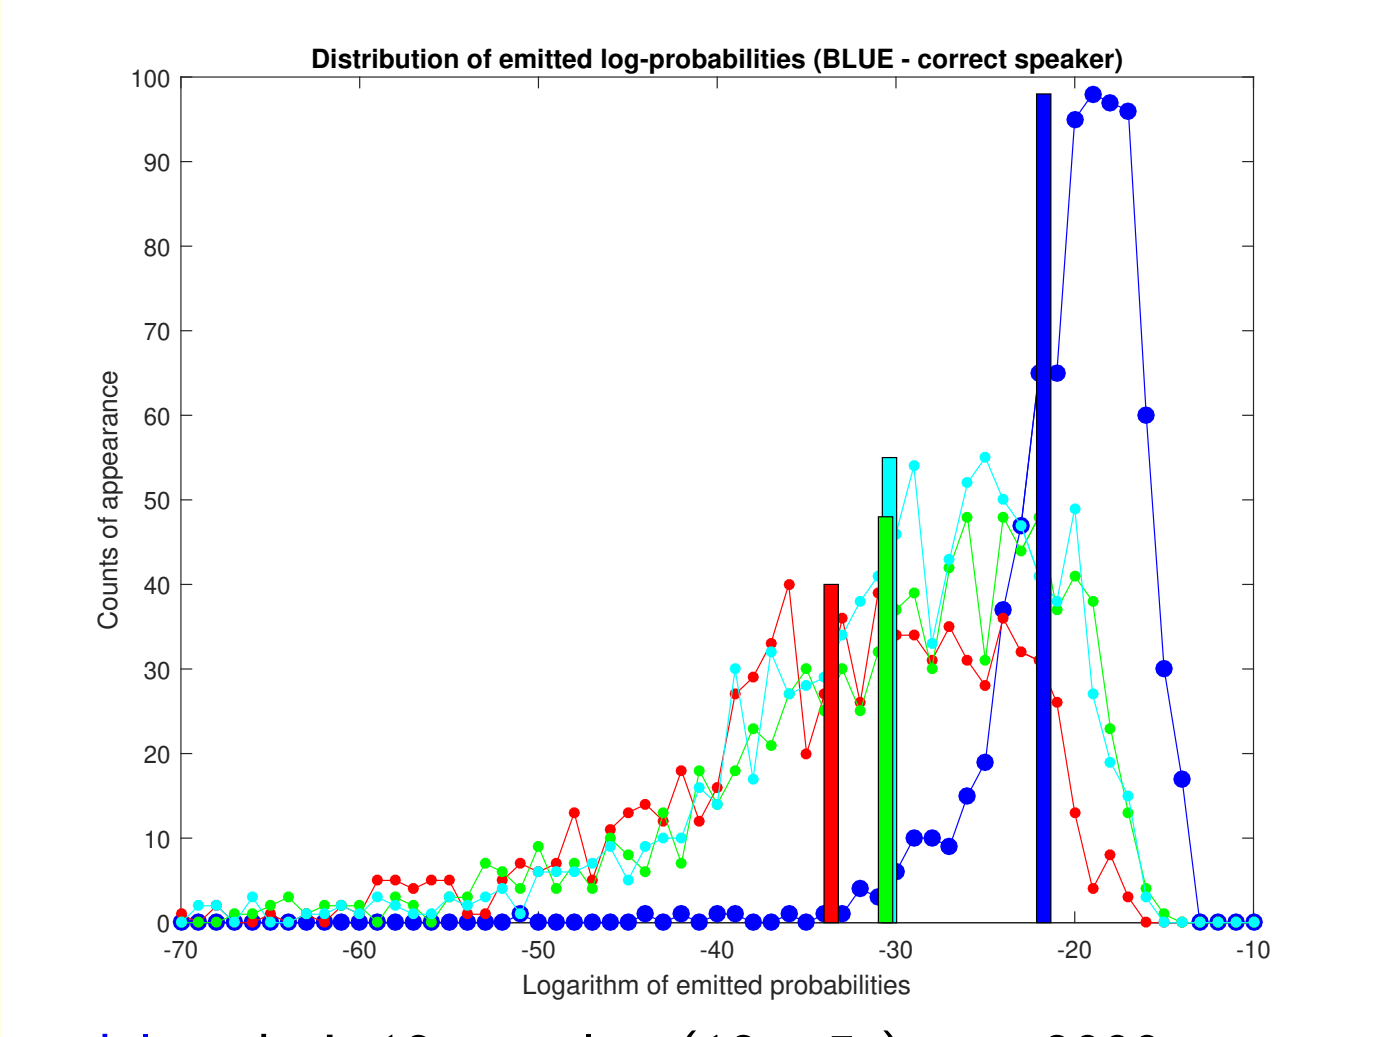

GMM model - zdroj: 12 promluv (12 x 5s), cca 2000 segmentů
- počet vážených směsí v GMM: 6

Identifikace - 20 promluv (20 x cca 1s), cca 1200 segmentů

Průměrné hodnoty logaritmické pravděpodobnosti

Rozpoznávání mluvčího na bázi UBM-GMM

Problém s trénování GMM modelu pro jednotlivého mluvčího

málo dat $\rightarrow$ malá schopnost generalizace

$\Downarrow$

UBM-GMM modelování

- UBM - Universal Background Model
  - generalizující model popisující společný prostor parametrů
  - vytvořený terénováním GMM pro velkou množinu mluvčích
- GMM model mluvčího - získaný adaptací UBM
  - nejčastěji MAP (Maximum Aposteriori Probability)
  - zápis mluvčího
    (neexistujícího v množině pro trénování UBM)
  - typicky velmi malé množství dat pro zápis
    (několik jednotlivých promluv, obvykle cca $3 \div 30s$)

Rozhodování UBM-GMM verifikace

$$\Lambda = log \frac{P(\mathbf{O}|\lambda^{spk})}{P(\mathbf{O}|\lambda^{UBM})}$$

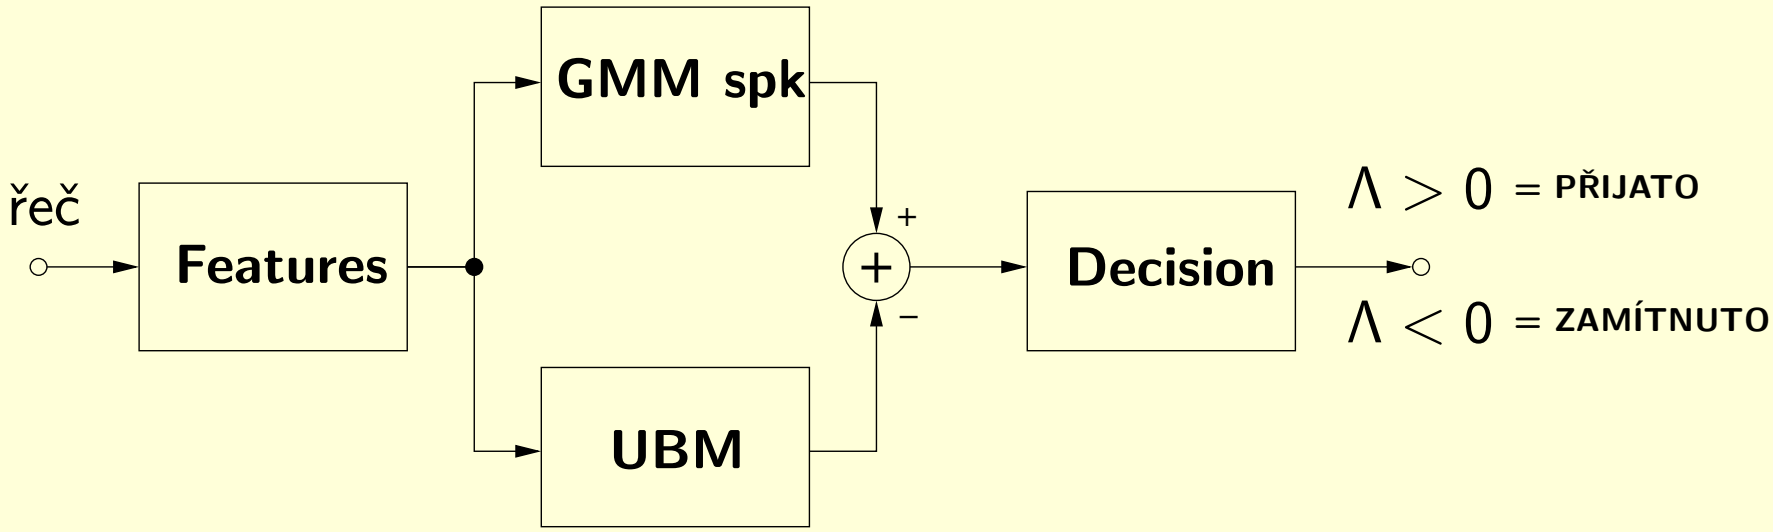

UBM-GMM $\rightarrow$ základ pokročilejších systémů na bázi i-vektorů

III. část

Textově nezávislá verifikace/identifikace na bázi i-vektorů

Definice a význam i-vektoru

GMM-UBM : adaptace UBM $\rightarrow$ GMM (pouze střední hodnoty)
Mluvčího charakterizují hodnoty vektoru středních hodnot
$\longrightarrow$ supervektor $\mathbf{m}_{r,s}$ (pro daného mluvčího):

- lze použít i pro reprezentaci nahrávek (různé délky)
- vektor délky $C \cdot F$ všech středních hodnot
  (C počet složek GMM, F počet použitých příznaků)
- NEVÝHODA - velká dimenze supervektoru

i-vektor - $\mathbf{x}_{r,s}$ - dimenze $D_{ivec} < CF$

- model supervektoru $\mathbf{m}_{r,s}$ na bázi faktorové analýzy (JFA)

$$\mathbf{m}_{r,s} = \boldsymbol{\mu} + \mathbf{T}\mathbf{x}_{r,s}$$

- společná složka pro všechny řečníky - supervektor $\boldsymbol{\mu}$
- složka jednoho řečníka - $\mathbf{T}\mathbf{x}_{r,s}$
  (generovaná transformací z vektoru menší dimenze $\mathbf{x}_{r,s}$)
- $\mathbf{x}_{r,s}$ (i-vektor) - popisuje specfické charakteristiky řečníka
- $\mathbf{T}$ - transformační matice dimenze $CF \times D_{ivec}$

Klasifikace na bázi i-vektorů

- trénování UBM - společný supervektor $\boldsymbol{\mu}$ (obecný korpus)
- EM odhad matice $\mathbf{T}$ (ze stejných dat jako UBM)
- i-vektor extraktor : $\mathbf{x}_{r,s} = \mathbf{T}^{-1} \cdot (\boldsymbol{\mu} - \mathbf{m}_{r,s})$
  kde $\mathbf{m}_{r,s}$ je supervektor řečníka resp. promluvy
  (získaný z GMM na bázi MAP adaptace UBM)
- i-vektor $\mathbf{x}_{r,s}$ = **reprezentace mluvčího/promluvy**

- klasifikace = srovnání dvou i-vektorů
  (SVM s jádrovou funkcí na bázi kosinové vzdálenosti)

$$score_{ivec} = \frac{\mathbf{x}_1^T \mathbf{x}_2}{||\mathbf{x}_1|| \cdot ||\mathbf{x}_2||}$$

- variabilita akustických podmínek není explicitně modelována
- možnosti potlačení variability akustických podmínek :
  - LDA (nalezení podprostoru s optimální rozlišitelností tříd)
  - WCCN (normalizace kovariance uvnitř tříd)
  - PLDA - $\mathbf{x}_{r,s} = \boldsymbol{\mu} + \mathbf{V}\mathbf{y}_s + \mathbf{U}\mathbf{w}_{r,s} + \boldsymbol{\epsilon}_{r,s}$
    (modelování variability akustických podmínek)

IV. část

Textově nezávislá verifikace/identifikace s hlubokými neuronovými sítěmi (DNN)

ANN/DNN - Artificial Neural Networks/Deep Neural Networks

Použití v SRE: - přímé, tj. výpočet pravděpodobnosti (klasifikace)
- **nepřímé**, tj. výpočet příznaků/reprezentace řečníka (embeddings)

VÝHODY:

- možnost natrénování složitější funkce
- možné rozšíření příznakového vektoru
  (řetězení příznaků se širším kontextem)
- přesnější výsledky lze dosáhnout s DNN
  (vícevrstvé sítě s hlubokým učením - deep learning)
- speciální struktury sítí (RNN, TDNN, CNN, LSTM)

NEVÝHODY:

- obecně náročnější trénování (algoritmy hlubokého učení)
- potřeba většího množství trénovacích dat
(nastavení mnoha vnitřních parametrů sítě)

Klasifikace na bázi ANN/DNN

Přímá klasifikace pomocí DNN (výpočet pravděpodobnosti)

- DNN ve funkci odhadu aposteriorní pravděpodobnosti řečníka

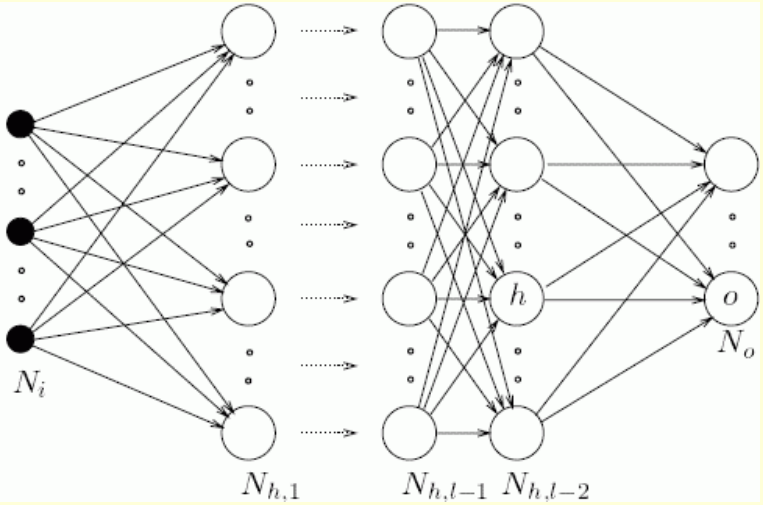

VSTUP: BF, kepstrum (MFCC), možný kontext několik oken

SKRYTÉ VRSTVY: 4-10

VÝSTUP: Softmax (aposteriors)

VARIANTA - DNN síť s bottleneck vrstvou (zúžení = komprese)

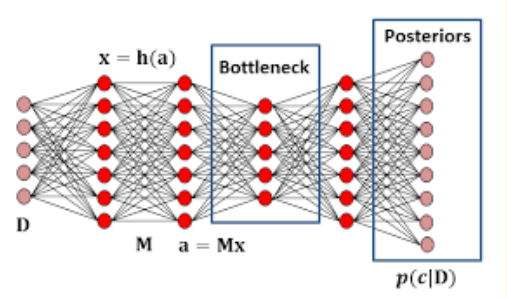

Nepřímé použití DNN: bottleneck výstup + MFCC (LDA, PCA)

$\rightarrow$ příznaky pro i-vektorový systém

TDNN - Time-Delay Neural Networks

TDNN vrstvy - zahrnují kontextovou informaci

tj. výstupy z předchozí vrstvy pro více časů (řetězení)

- používá se plný či částečný kontext
- pro více TDNN vrstev $\rightarrow$ zvyšující se kontext

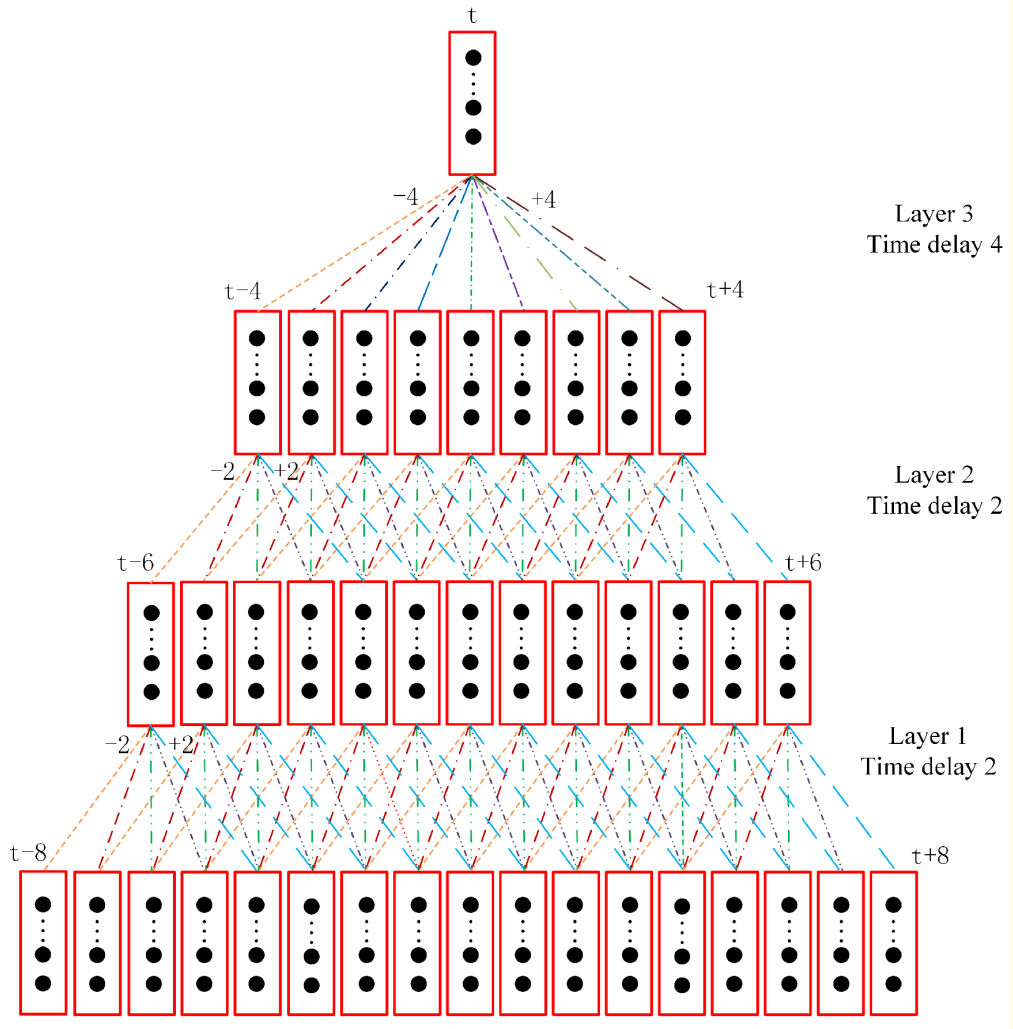

Aktuální DNN standard: systém na bázi x-vektorů (cca 2018+)

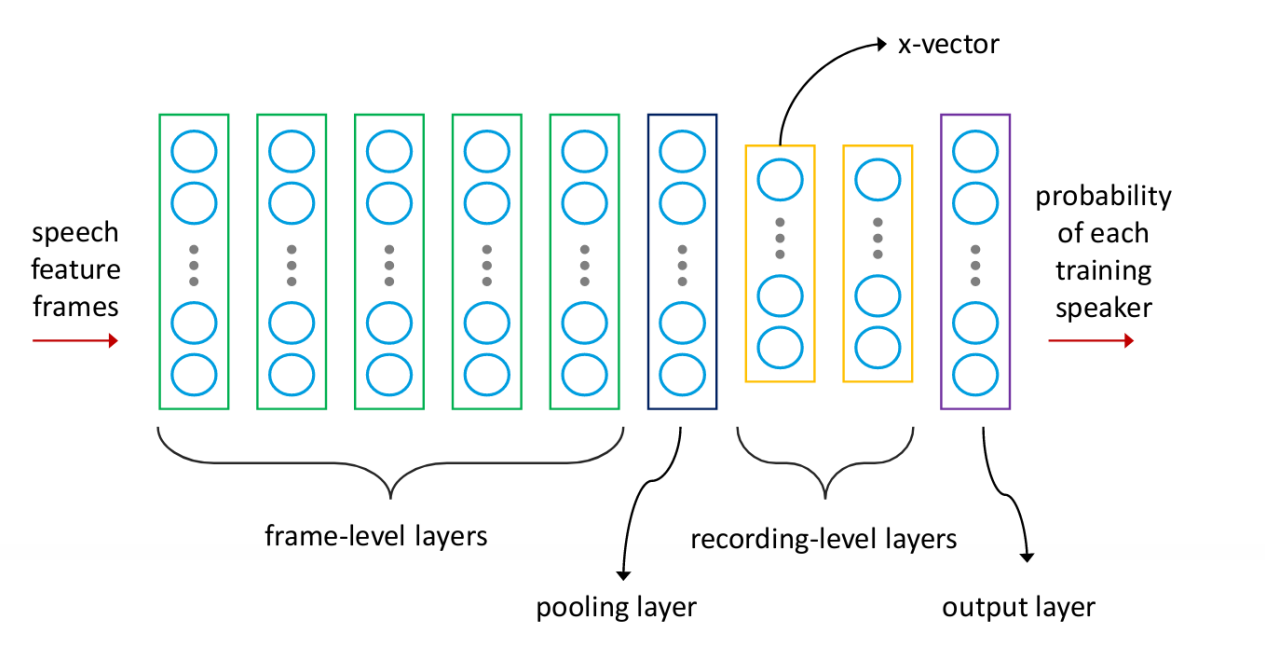

- vstupní příznaky jsou zpracovány v 5 TDNN vrstvách, zvyšující se zpoždění zahrnuje potřebnou kontextovou informaci (Δ příznaky nejsou používány)
- 6. poolingová vrstva počítá střední hodnoty a standardní odchylky výstupu 5. vrstvy přes všechny segmenty nahrávky
- dopředné (bottleneck) vrstvy 7 a 8 zahrnují reprezentaci mluvčího-nahrávky $\rightarrow$ x-vektor (příznaky pro SRE)
- 9. výstupní softmax vrstva realizuje identifikaci řečníka (využíváno v trénovací fázi)

Aktuální DNN standard: systém na bázi x-vektorů (cca 2018+)

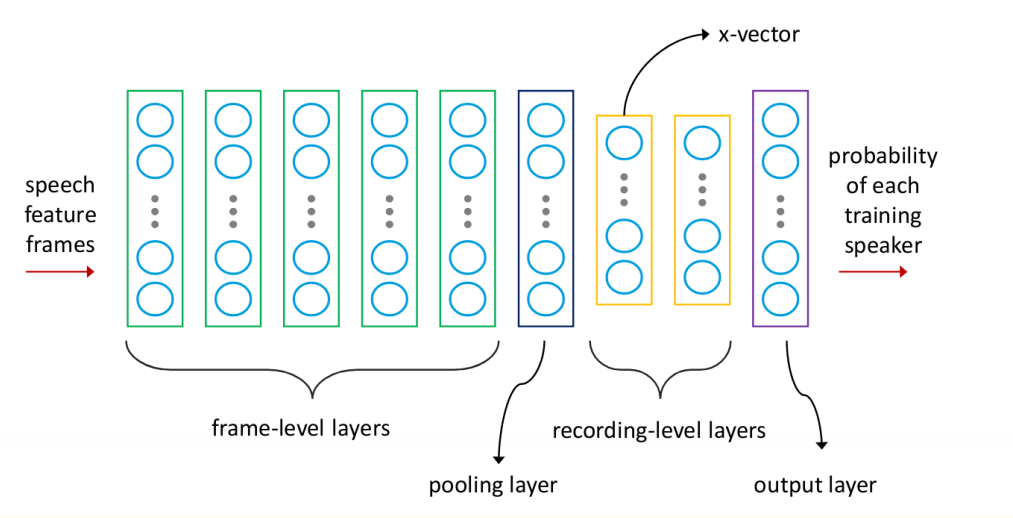

Vrstva	Kontext vrstvy	Celkový kontext	Vstup x výstup
frame1	t-2 ÷ t+2	5	120 x 512
frame2	t-2, t, t+ 2	9	1536 x 512
frame3	t-3, t, t+ 3	15	1536 x 512
frame4	t	15	512 x 512
frame5	t	15	512 x 1500
stats pooling	0 ÷ T	T	1500T x 3000
segment6	0	T	3000x512
segment7	0	T	512x512
softmax	0	T	512xN

vstup 24 pásem melovské BF, pooling přes počet segmentů T, N řečníků

Více detailů viz: Snyder et al: X-Vectors: Robust DNN Embeddings for Speaker Recognition. In ICASSP 2018

Přímá klasifikace na bázi CNN (Convolution Networks)

Principiální schéma CNN:

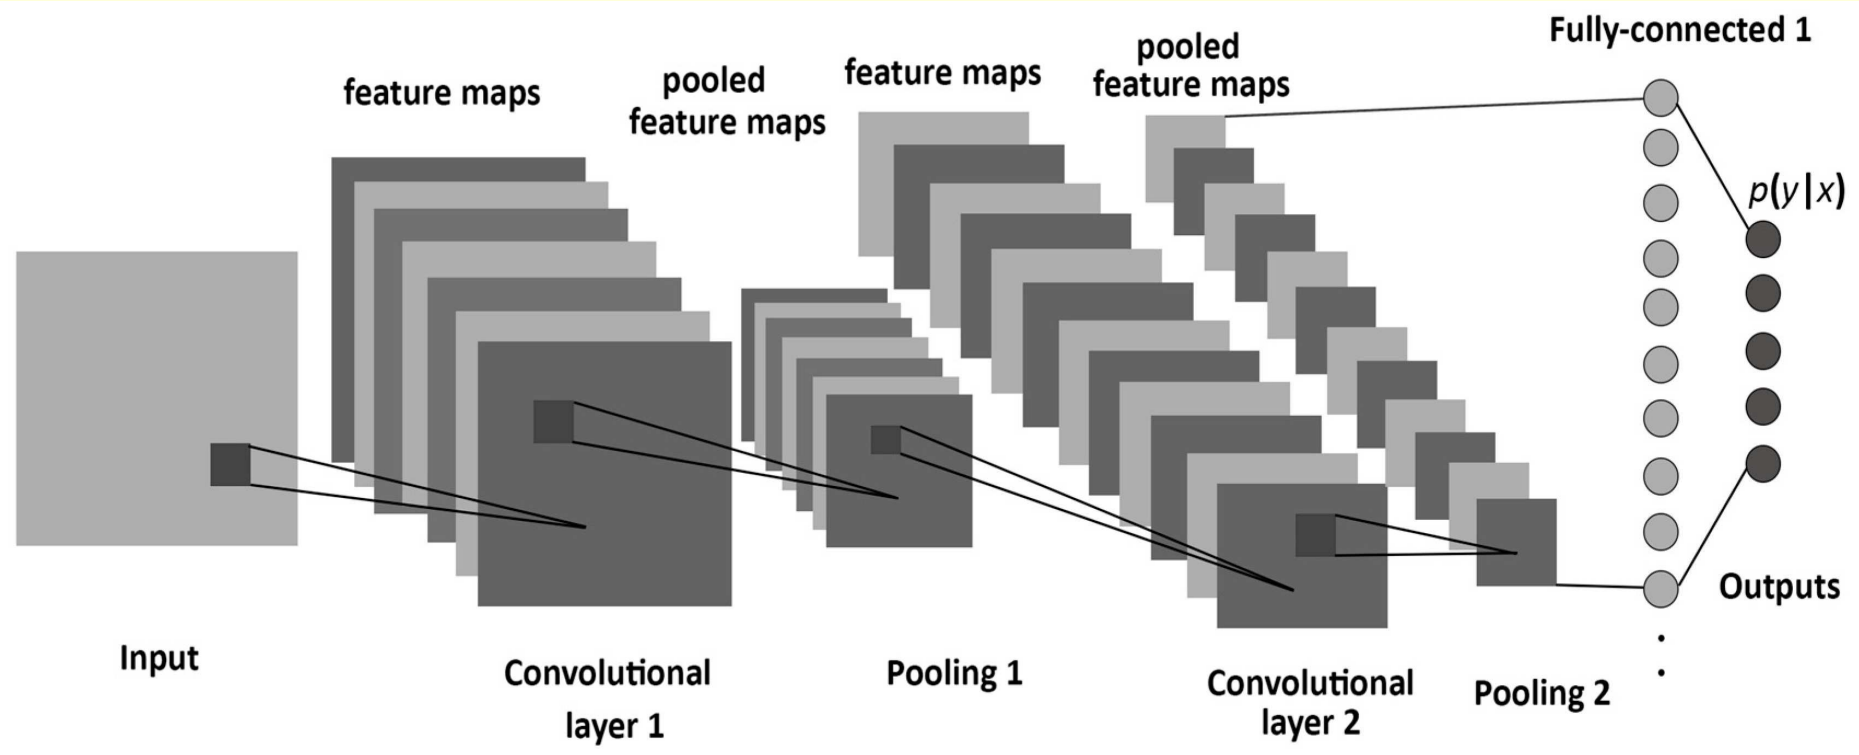

Nejčastější aplikace CNN ve zpracování obrázků

Aplikace pro SRE: vstupem je spektrogram (obrázek) či signál

→ End-to-End Recognition (klasifikace bez výpočtu příznaků)

CNN Siamese Speaker Verification

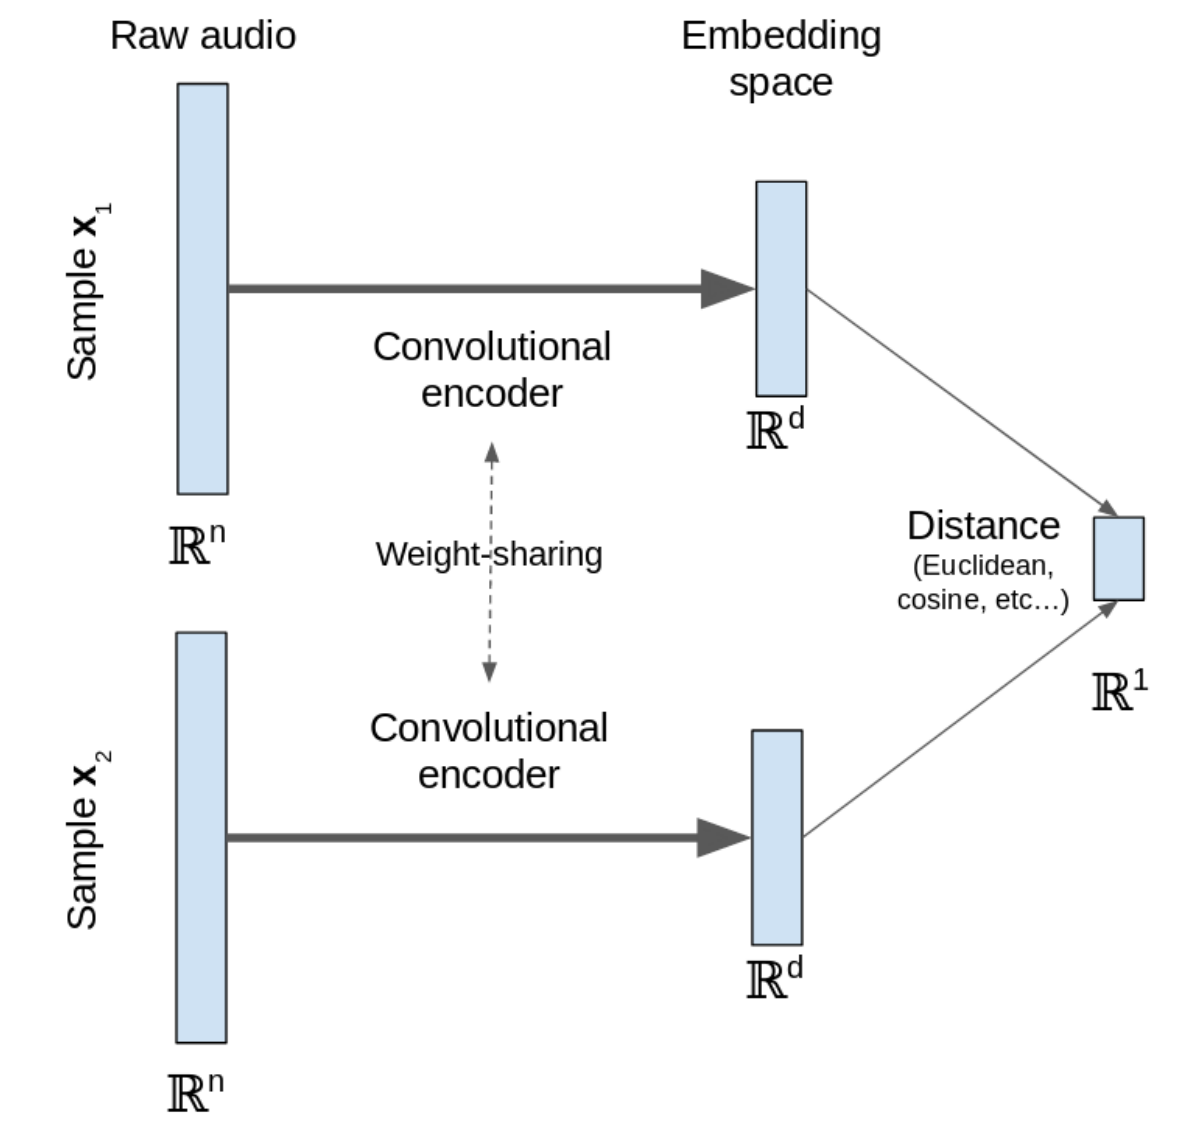

ECAPA-TDNN-based Speaker Verification (cca 2020+)

B. Desplanques, J. Thienpondt, K. Demuynck: ECAPA-TDNN: Emphasized Channel Attention, Propagation and Aggregation in TDNN Based Speaker Verification. In INTERSPEECH 2020

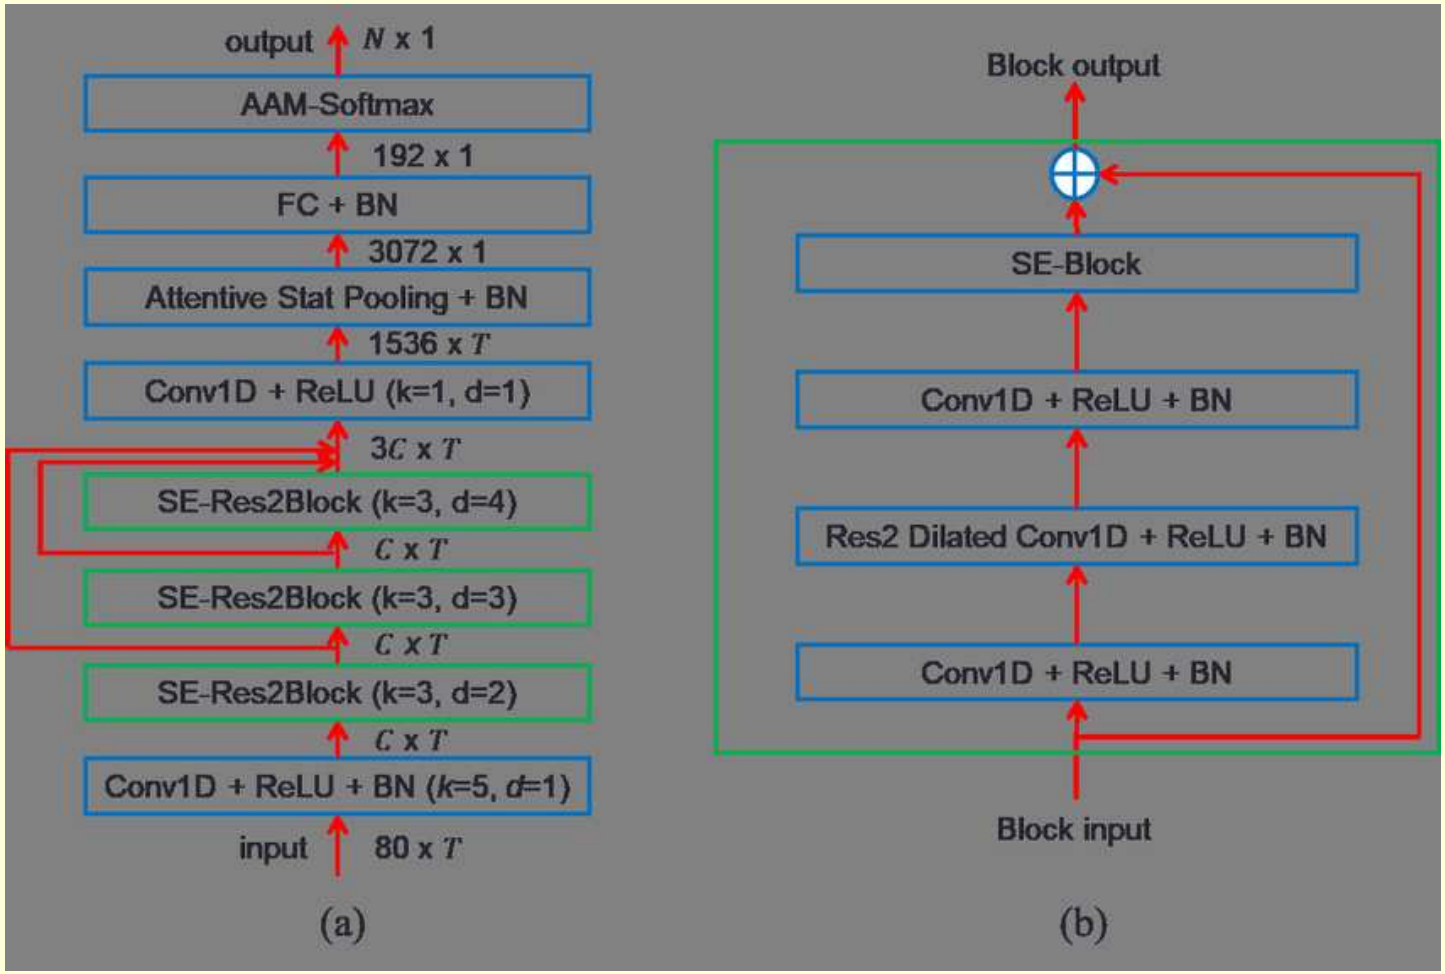

Speaker embedding - dimension 192 - last FC (bottleneck) layer

V. část

Příklady systémů rozpoznávání řečníka

Hodnotící kritéria při verifikaci mluvčího - Míra stejné chyby

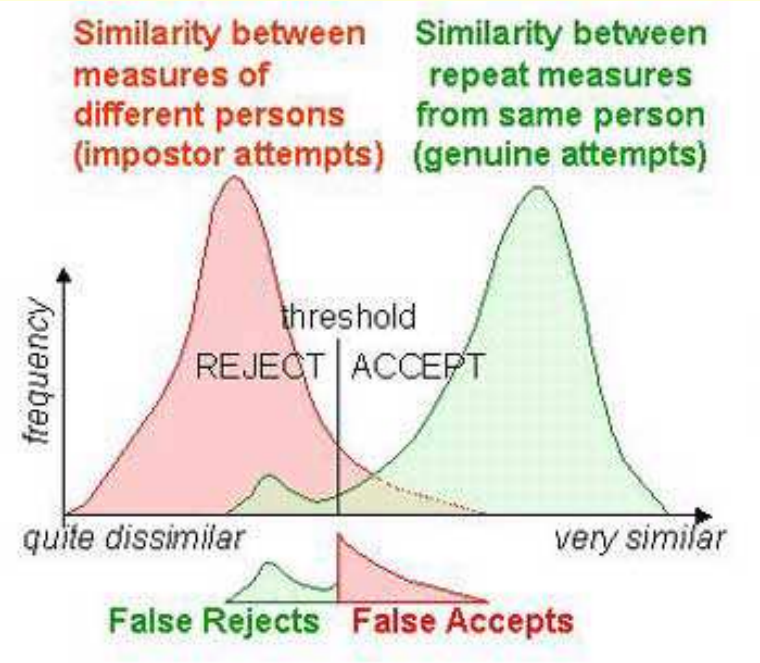

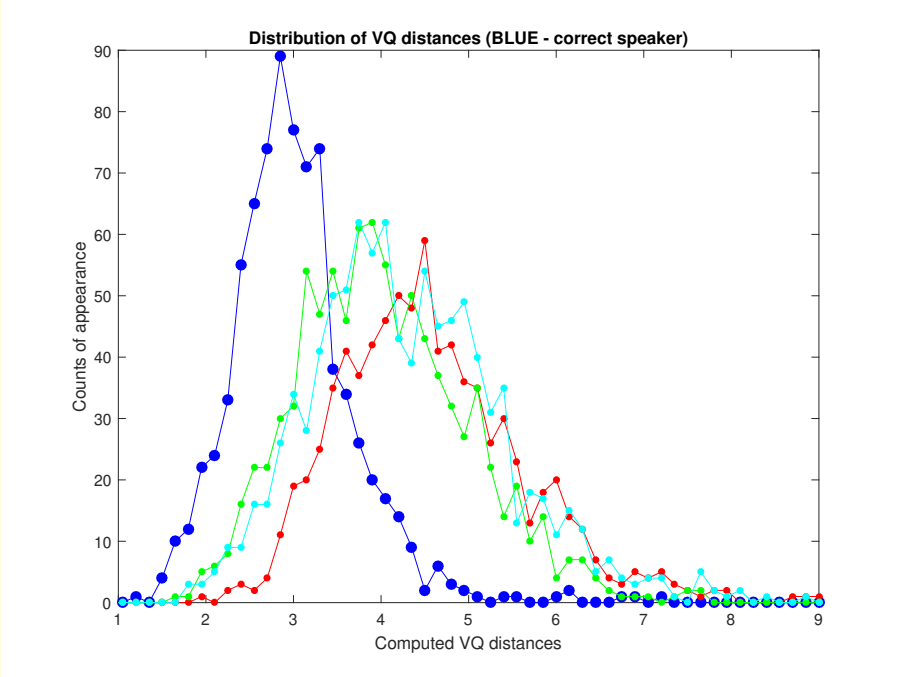

TA - True acceptance

FA - False acceptance: $R_{FA} = \frac{N_{FA}}{N_{podv}}$

TR - True rejection

FR - False rejection $R_{FR} = \frac{N_{FR}}{N_{spref}}$

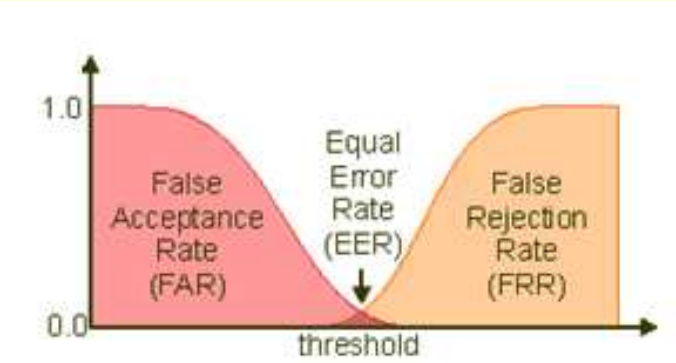

EER - Equal Error Rate

Míra stejné chyby :

$$EER = R_{FR}(P_{thr}) = R_{FA}(P_{thr})$$

Historické systémy verifikace

Autor	Příznaky	Metoda	Text	Vstup	Error
Atal'74	kepstr.	Pattern	depend.	LAB	2% (1s)
Fururi'81	nor. kepstr.	Pattern	depend.	TEL	0,2% (3s)
Doddington'85	FB	DTW	depend.	LAB	0,8% (6s)
Tishby'91	kepstr.	HMM	10 digits	TEL	2,8% (1,5s) 0,8% (3,5s)
Reynolds'96	MFCC+Δ	GMM	indep.	TEL match.	11% (3s) 6% (10s) 3% (30s)
Reynolds'96	MFCC+Δ	GMM	indep.	TEL mism.	16% (3s) 8% (10s) 5% (30s)

Více detailů viz: J. R. Campbell: Speaker Recognition. Department of Defense Fort Meade, MD, at http://scgwww.epfl.ch

Standardy na bázi UBM-GMM (konec 90. let - cca 2012)

NIST 2010 - Speaker verification evaluations.

- výsledky verifikace pro rozdílné evaluační podmínky
- GMM-UBM systémy (UBM - Universal Background Model)
- EER - Equal Error Rate

	mic-mic	mic-mic2	mic-tel	tel-tel
Systém 1 - muži	8,39	17,29	16,24	15,68
Systém 1 - ženy	13,5	23,47	18,42	17,18
Systém 1 - AVG	10,94	20,38	17,54	16,52
Systém 2	6,00	8,64	5,32	5,11

Systém 1 - 8kHz, 25/10 ms, preemfáze, 16 MFCC ($+\Delta$, $+\Delta\Delta$), log energie, energetický VAD, normalizace příznakových vektorů, 512 směsí

Systém 2 - 8kHz, 25/10 ms, 19 MFCC & $c[0]$ ($+\Delta$), detektor řeči na bázi automatického přepisu (rozpoznávání), normalizace příznakových vektorů, adaptace akustických modelů, 512 směsí

Systémy na bázi i-vektorů - cca 2010-2020

Interpseech 2016:

The IBM Speaker Recognition System
EER 2.11% - GMM-UBM (i-vector) - MFCC - LDA
EER 1.49% - GMM-UBM (i-vector) - MFCC - NDA
(NDA - Nearest-neighbour discriminant analysis)
EER 0.59% - DNN-fMLLR-NDA (English)

SITW - Speakers In The Wild - core-core
Speakers In The Wild Database (for speaker recognition)
- 299 speakers, 8 different sessions per speaker
- mismatch of acoustic conditions
- "core" conditions (data from one person of interest)
- training 6180 seconds
- test 6-180 s of speech per file

Brno University of Technology : EER = 5.85%
Quensland University of Technology, Australia : EER = 8.69%

SRE na bázi x-vektorů - 2018-současnost

Hossein Zeinali, Kong Aik Lee, Jahangir Alam, Lukas Burget: **SdSV** Challenge 2020: Large-Scale Evaluation of **Short-duration Speaker Verification** (**Interspeech 2020:**)

- velmi krátké promluvy k verifikaci
- významná závislost na fonetickém kontextu (obsahu) (proto textově závislé i textově nezávislé úlohy)
- většina systémů na bázi x-vektorů

1. Textově závislá verifikace (*5 nejlepších týmů*)
   - promluvy pro zápis - avg 7.6s, testovací promluvy - avg 2.6s
   T56: EER 1.45 % , T14: EER 1.45 %, T10: EER 1.58 % ,
   T08: EER 1.62 %, T34: EER 2.09 %, T26: EER 2.10 %
2. Text independent verification (*6 nejlepších týmů*)
   - promluvy pro zápis - náhodně 4-180s (avg 49),
   - testovací promluvy - avg 2.6s
   T37: EER 1.45 % , T35: EER 1.51 %, T41: EER 1.77 %,
   T64: EER 1.84 % , T05: EER 2.00 %, T10: EER 2.32 %

SRE na bázi x-vektorů - 2018-současnost

Hossein Zeinali, Kong Aik Lee, Jahangir Alam, Lukas Burget: **SdSV** Challenge 2020: Large-Scale Evaluation of **Short-duration Speaker Verification** (**Interspeech 2020:**)

- velmi krátké promluvy k verifikaci
- významná závislost na fonetickém kontextu (obsahu) (proto textově závislé i textově nezávislé úlohy)
- většina systémů na bázi x-vektorů

1. Textově závislá verifikace (*5 nejlepších týmů*)
   - promluvy pro zápis - avg 7.6s, testovací promluvy - avg 2.6s
   T56: EER 1.45 % , T14: EER 1.45 %, T10: EER 1.58 % ,
   T08: EER 1.62 %, T34: EER 2.09 %, T26: EER 2.10 %
2. Text independent verification (*6 nejlepších týmů*)
   - promluvy pro zápis - náhodně 4-180s (avg 49),
   - testovací promluvy - avg 2.6s
   T37: EER 1.45 % , T35: EER 1.51 %, T41: EER 1.77 %,
   T64: EER 1.84 % , T05: EER 2.00 %, T10: EER 2.32 %

ECAPA-TDNN speaker verification - 2020-současnost

Příklady verifikace a trénování na korpusech VoxCeleb1/2 (celebrity z YouTube, 1251+5994 spks, 4-20s) augmentace s databází šumů (MUSAN) a modelování dozvuku (RIR)

- B. Desplanques, J. Thienpondt, K. Demuynck: ECAPA-TDNN: Emphasized Channel Attention, Propagation and Aggregation in TDNN Based Speaker Verification. In Interspeech 2020.

  Train VoxCeleb2+MUSAN+RIR - test VoxCeleb1-O **EER 0.87** %

- S. Peng, W. Guo, H. Wu, Z, Li, J. Zhang: Fine-tune Pre-Trained Models with Multi-Level Feature Fusion for Speaker Verification In Interspeech 2024.

  Train VoxCeleb2+MUSAN+RIR - test VoxCeleb1-O **EER 0.633** %

- S-H. Liou et al : Enhancing ECAPA-TDNN with Feature Processing Module and Attention Mechanism for Speaker Verification In Interspeech 2024.

  Train VoxCeleb2+MUSAN+RIR - test VoxCeleb1-O **EER 0.798** %

ASV za přítomnosti podvržené řeči - SASV

S. Peng, W. Guo, H. Wu, Z, Li, J. Zhang: Spoofing-Aware Speaker Verification by Multi-Level Fusion. In Interspeech 2022.

Bonafide vs. spoof data - 3 možné chyby:

- EER_{SV} (standardní ASV, tj pouze bonafide)
- EER_{SPF} (ASV pouze spoof)
- EER_{SASV} (ASV bonafide + spoof)

BASELINE SPEAKER VERIFICATION

(bez antispoof modifikace, ECAPA-TDNN, Interspeech 2020)

$$EER_{SV} = \mathbf{1.86}, \quad EER_{SPF} = 30.75, \quad EER_{SASV} = 23.84$$

ANTI-SPOOF ONLY

(AASIST, state-of-the-art CM model, ICASSP 2022)

$$EER_{SV} = 49.24, \quad EER_{SPF} = \mathbf{0.67}, \quad EER_{SASV} = 24.38$$

SPOOFING-AWARE SPEAKER VERIFICATION

Systém H5: $EER_{SV} = 1.15$, $EER_{SPF} = 0.56$, $EER_{SASV} = \mathbf{0.97}$

Systém G4: $EER_{SV} = 1.21$, $EER_{SPF} = 0.83$, $EER_{SASV} = 1.08$

Systém D: $EER_{SV} = 1.47$, $EER_{SPF} = 1.08$, $EER_{SASV} = 1.35$

Five best: $EER_{SV} = 1.01$, $EER_{SPF} = 0.71$, $EER_{SASV} = \mathbf{0.89}$

Děkuji vám za pozornost !