


## پردازش گفتار

# نمایش‌های سیگنال گفتار و استخراج ویژگی

هادی ویسی

[h.veisi@ut.ac.ir](mailto:h.veisi@ut.ac.ir)

دانشگاه تهران - دانشکده علوم و فنون نوین



## فهرست

- مدل منبع-فیلتر
- تحلیل فوریه کوتاه‌مدت
- تحلیل LPC
  - محاسبه ضرایب LPC
  - تحلیل طیفی و خطای پیش‌بینی
  - کاربردها و مثال
- تحلیل کپستروم
  - مثال
- MFCC
- روش (Pitch) فرکانس زیروبمی


## مدل منبع-فیلتر . . .

### ○ هدف

- نمایش و مدل‌سازی سیگنال گفتار
- کاربرد در کلیه سیستم‌های پردازش‌های گفتار
- رمزگذاری، شبیه‌سازی، سنتز گفتار، تشخیص گفتار و ...

### ○ تجزیه سیگنال گفتار

- منبعی که از فیلتر خطی متغیر با زمان عبور می‌کند
- منبع = جریان هوا در تارهای صوتی
- فیلتر = نشانگر رزنانس‌های مجرای گفتار





## مدل منبع-فیلتر

### ○ تخمین فیلتر $h[n]$


- روش‌های مبتنی بر مدل‌های تولید گفتار

- رمزگذاری پیش‌بینی خطی (linear predictive coding)

- تحلیل کپسکتروال (cepstral analysis)

- روش‌های مبتنی بر مدل‌های دریافت گفتار

- کپسکتروم مل-بسامد (mel-frequency cepstrum)



### ○ تخمین منبع $e[n]$

- بعد از تخمین فیلتر


- محاسبه منبع با عبور دادن سیگنال گفتار از فیلتر معکوس

## تحلیل فوریه کوتاه‌مدت . . .

- عدم ایستا (stationary) بودن سیگنال گفتار
  - مشخصات آن با زمان تغییر می‌کند
- سیگنال در طول ادای یک واژ (۲۵ تا ۲۵۰ میلی ثانیه) تقریباً ایستاست
- با تقریب، فرض می‌شود سیگنال گفتار در زمان‌های کوتاه ایستا است
  - یک بخش کوتاه‌مدت سیگنال گفتار = فریم (قاب)
  - طول هر فریم باید به گونه‌ای باشد که شامل فقط یک واژ و یا واژ‌گونه باشد
- طول هر قاب در کاربردهای واقعی: بین ۱۰ تا ۵۰ میلی ثانیه

## تحلیل فوریه کوتاه مدت . . .

- تجزیه سیگنال گفتار به مجموعه‌ای از بخش‌های کوتاه (فریم=قاب)
- طول فریم‌ها باید به اندازه کافی کوچک = سیگنال ایستا (stationary) باشد
  - مشخصات آماری سیگنال ثابت باشد
  - ثبت ماندن رفتار سیگنال (دوره‌ای بودن یا ظاهر شبیه به نویز داشتن)



## تحلیل فوریه کوتاه‌مدت . . .


### ○ سیگنال کوتاه‌مدت

قاب = سیگنال کوتاه‌مدت

$$X_m[n] = x[n] w_m[n]$$


(window)

- پنجره به جز در یک منطقه کوچک (طول مشخص) در همه جا صفر است
- هر چند تابع پنجره می‌تواند مقادیر مختلفی برای قالب‌های مختلف  $m$  داشته باشد اما معمولاً پنجره برای تمامی قاب‌ها یکسان است



$$w_m[n] = w[m-n]$$

- که در آن  $w[n] = 0$  for  $|n| > N/2$



- نمایش فوریه کوتاه‌مدت برای قاب  $m$


$$X_m(e^{j\omega}) = \sum_{n=-\infty}^{\infty} X_m[n] e^{-j\omega n} = \sum_{n=-\infty}^{\infty} w[m-n] x[n] e^{-j\omega n}$$

## تحلیل فوریه کوتاه‌مدت . . .

$$h_\pi[n] = u[n] - u[n-N]$$


$$H_\pi(e^{j\omega}) = \frac{1 - e^{-j\omega N}}{1 - e^{-j\omega}} = \frac{(e^{j\omega N/2} - e^{-j\omega N/2})e^{-j\omega N/2}}{(e^{j\omega/2} - e^{-j\omega/2})e^{-j\omega/2}}$$

$$= \frac{\sin \omega N/2}{\sin \omega/2} e^{-j\omega(N-1)/2} = A(\omega) e^{-j\omega(N-1)/2}$$



$$h_h[n] = \begin{cases} (1-\alpha) - \alpha \cos(2\pi n/N) & 0 \leq n < N \\ 0 & \text{otherwise} \end{cases}$$

$$H_h(e^{j\omega}) = (1-\alpha)H_\pi(e^{j\omega}) - (\alpha/2)H_\pi(e^{j(\omega-2\pi/N)}) - (\alpha/2)H_\pi(e^{j(\omega+2\pi/N)})$$





• همینگ (Hamming)

• معمولاً  $\alpha = 0.46$

## تحلیل فوریه کوتاه مدت . . .

### ○ پنجره‌گذاری



Rectangular:  $w[n] \equiv 1$



Hanning:  $0.5 + 0.5c_1$



$$c_k = \cos \frac{2\pi kn}{M+1}$$

rapid sidelobe decay



Hamming:  $0.54 + 0.46c_1$

best peak sidelobe



انتخاب بهتر!



## تحلیل فوریه کوتاه‌مدت . . .

- برای سیگنال دوره‌ای  $X_m[n]$  با دوره  $M$  داریم

$$X_m(e^{j\omega}) = \sum_{k=-\infty}^{\infty} X_m[k] \delta(\omega - 2\pi k / M)$$

- تبديل فوريه پنجره  $= \mathbf{w}[n]$

$$W(e^{-j\omega}) e^{-j\omega m} = \mathbf{w}[m-n]$$

- بنابراین (تبديل فوريه یک قاب)
- ضرب در حوزه زمان ( $x[n]w[m-n]$ ) معادل کانولوشن در حوزه فرکانس است

$$X_m(e^{j\omega}) = \sum_{n=-\infty}^{\infty} X_m[n] e^{-j\omega n} = \sum_{n=-\infty}^{\infty} w[m-n] x[n] e^{-j\omega n} = \sum_{k=-\infty}^{\infty} X_m[k] W(e^{j(\omega - 2\pi k / N)}) e^{j(\omega - 2\pi k / N)m}$$

- جمع وزن‌دار ( $W(e^{j\omega})$  ها)

## تحلیل فوریه کوتاه مدت . . .

$$W(e^{j\omega}) \approx 0 \text{ for } |\omega - \omega_k| > \lambda$$

برای بازیابی  $\mathbf{x}_m[n]$  از  $X_m(e^{j\omega})$  باید

- پاسخ فرکانسی پنجره در خارج از lobe اصلی صفر باشد

$$\lambda = 4\pi/N \quad \text{و برای پنجره همینگ} \quad \lambda = 2\pi/N$$

پس برای پنجره مستطیلی باید  $N \geq M$  (دوره تناوب سیگنال)

- طول پنجره حداقل یک دوره تناوب زیروبمی (pitch period) باشد

$$N \geq 2M \quad \text{و برای پنجره همینگ}$$

- طول پنجره حداقل دو دوره تناوب زیروبمی (pitch period) باشد

در عمل: مقدار زیروبمی را نداریم = در نظر گرفتن کمترین مقدار  $F_0$

- برای  $F_0 = 50\text{Hz}$  باید  $N = 20\text{ ms}$  (برای مستطیلی) و  $N = 40\text{ ms}$  (برای همینگ)

اگر سیگنال با طول  $40\text{ ms}$  غیرایستا باشد؟؟

- پنجره مستطیلی تفکیک زمانی (Time Resolution) بهتری نسبت به پنجره همینگ فراهم می‌کند

## تحلیل فوریه کوتاه مدت . . .

### ○ از طرفی

- پاسخ فرکانسی خارج از lobe اصلی صفر نیست
- دامنه فرکانس در lobe دوم در مستطیلی 17 dB و برای همینگ حدود 44 dB کمتر از lobe اصلی است (برای همینگ حدود 31 dB)
- پس هارمونیک kام  $X_m(k) e^{j2\pi k/M}$  نه تنها حاوی (i) بلکه حاوی جمع وزن دار  $X_m(k)$  نیز است
- نشت طیفی (spectral leakage)


در عمل  
انتخاب بهتر!

### ○ پنجره مستطیلی یا همینگ؟

مقایسه	همینگ	مستطیلی	ویژگی
مستطیلی بهتر است	دو دوره تناوب زیروبمی	یک دوره تناوب زیروبمی	طول پنجره (Time Resolution)
همینگ بهتر است	44 dB کمتر از lobe اصلی	17 dB کمتر از lobe اصلی	نشت طیفی (Spectral Leakage)


در عمل: طول پنجره حدود 20 تا 30 میلی ثانیه

## تحلیل فوریه کوتاه مدت . . .



## تحلیل فوریه کوتاه مدت . . .

● مثال: واچ بی‌واک




● مستطیلی

● سیگنال نامنظم

● همینگ

## تحلیل فوریه کوتاه مدت




### طیف‌نگار

- باند پهن
  - پنجره زمانی کوتاه
  - کمتر از ۱۰ میلی ثانیه
  - تفکیک زمانی خوب
  - تفکیک بسامد پایین‌تر
  - فیلترهای پهن ( $>200\text{Hz}$ )
- باند باریک
  - پنجره زمانی بلند
  - بزرگتر از ۲۰ میلی ثانیه
  - تفکیک زمانی کمتر
  - تفکیک بسامد بهتر
  - فیلترهای باریک ( $<100\text{Hz}$ )




## مدل منبع-فیلتر



### ○ مدل منبع-فیلتر (Source-Filter)

- تولید گفتار واکدار و بیواک




### ○ نحوه تخمین فیلتر؟ منبع؟



## تحلیل ...LPC

### ○ رمزگذاری پیش‌بینی کننده خطی (LPC: Linear Predictive Coding)

- مبانی ریاضی از سال ۱۹۲۷ (Yule) و ۱۹۳۱ (Walker)
- الگوریتم بدست آوردن ضرایب در ۱۹۴۷ (Levinson) و ۱۹۶۰ (Durbin)
- تحلیل LPC یا مدل‌سازی خود بازگشتی (AR: Auto-Regressive)
- روش پرکاربرد در نمایش سیگنال گفتار و تخمین پارامترهای اصلی آن (سریع و ساده)
- تخمین فیلتر (و منبع) در مدل منبع-فیلتر
- امکان مدل کردن  $H(z)$  با یک فیلتر تمام-قطب (با تعداد قطب‌های کافی)



تعداد P قطب

$$H(z) = \frac{X(z)}{E(z)} = \frac{1}{1 - \sum_{k=1}^P a_k z^{-k}} = \frac{1}{A(z)}$$



## تحلیل ... LPC

$$A(z) = 1 - \sum_{k=1}^p a_k z^{-k}$$

### فیلتر معکوس (تولید صدا)



$$x[n] = \sum_{k=1}^p a_k x[n-k] + e[n]$$

### در حوزه زمان (معکوس تبدیل Z)

تخمین نمونه  $x[n]$  ام سیگنال از روی  $P$  نمونه قبلی (و سیگنال تحریک) =

LPC = مرتبه تحلیل

LPC = ضرایب تحلیل

سیگنال تحریک (Excitation)  
باقي‌مانده (Residual)

$$\tilde{x}[n] = \sum_{k=1}^p a_k x[n-k]$$

### تخمین

$$e[n] = x[n] - \tilde{x}[n] = x[n] - \sum_{k=1}^p a_k x[n-k]$$

### خطای تخمین

مساله: نحوه پیدا کردن ضرایب  $a_k$  ؟

# تحلیل LPC: محاسبه ضرایب ...

○ هدف: کمینه کردن خطای تخمین

- مربعات خطای برای قاب سیگنال گفتار  $x_m[n]$


$$E_m = \sum_n e_m^2[n] = \sum_n (x_m[n] - \tilde{x}_m[n])^2 = \sum_n \left( x_m[n] - \sum_{j=1}^p a_j x_m[n-j] \right)^2$$

ضرب داخلی خطا و سیگنال

- مشتق‌گیری بر حسب  $a_i$  و برابر صفر قرار دادن

$$\langle e_m, x_m^i \rangle = \sum_n e_m[n] x_m[n-i] = 0 \quad 1 \leq i \leq p$$

اصل تعامد (Orthogonality Principle): بردار خطای تخمین گر بهینه (از نظر مربعات خطای) بر نمونه‌های قبلی سیگنال متعماد است



# تحلیل LPC: محاسبه ضرایب ...

## ○ معادلات

$$\langle \mathbf{e}_m, \mathbf{x}_m^i \rangle = \sum_n e_m[n] x_m[n-i] = 0 \quad 1 \leq i \leq p$$

$$e[n] = x[n] - \tilde{x}[n] = x[n] - \sum_{k=1}^p a_k x[n-k]$$

$$\sum_n x_m[n-i] x_m[n] = \sum_{j=1}^p a_j \sum_n x_m[n-i] x_m[n-j] \quad i = 1, 2, \dots, p$$

$$\phi_m[i, j] = \sum_n x_m[n-i] x_m[n-j] \quad \bullet \text{ تعریف ضرایب همبستگی}$$

$$\sum_{j=1}^p a_j \phi_m[i, j] = \phi_m[i, 0] \quad i = 1, 2, \dots, p \quad \bullet \text{ آنگاه داریم (معادله Yule-Walker)}$$

• معمولاً خطای تخمین به گونه‌ای نرمال می‌شود که انرژی آن واحد باشد

$e_m[n] = G u_m[n]$  • رابطه بین خطای اصلی و خطای نرمال شده

$$E_m = \sum_n e_m^2[n] = G^2 \sum_n u_m^2[n] = G^2 \quad \bullet \text{ آنگاه مقدار خطای تخمین} =$$

# تحلیل LPC: محاسبه ضرایب ...

## روش‌های حل معادلات

- روش کوواریانس (Covariance)

- روش خودهمبستگی (Autocorrelation)

- روش لاتیس: لوینسون-دوربین (Levinson-Durbin)



## تحلیل LPC: محاسبه ضرایب ...

$$\phi_m[i, j] = \sum_{n=0}^{N-1} x_m[n-i]x_m[n-j] = \sum_{n=-i}^{N-1-j} x_m[n]x_m[n+i-j] = \phi_m[j, i]$$

روش کواریانس . . .

$$\sum_{j=1}^p a_j \phi_m[i, j] = \phi_m[i, 0] \quad i = 1, 2, \dots, p$$

$$\begin{pmatrix} \phi_m[1,1] & \phi_m[1,2] & \phi_m[1,3] & \cdots & \phi_m[1,p] \\ \phi_m[2,1] & \phi_m[2,2] & \phi_m[2,3] & \cdots & \phi_m[2,p] \\ \phi_m[3,1] & \phi_m[3,2] & \phi_m[3,3] & \cdots & \phi_m[3,p] \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \phi_m[p,1] & \phi_m[p,2] & \phi_m[p,3] & \cdots & \phi_m[p,p] \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ a_3 \\ \cdots \\ a_p \end{pmatrix} = \begin{pmatrix} \phi_m[1,0] \\ \phi_m[2,0] \\ \phi_m[3,0] \\ \cdots \\ \phi_m[p,0] \end{pmatrix} \rightarrow \Phi \mathbf{a} = \boldsymbol{\psi}$$

تجزیه ماتریس  $\Phi = V D V^t$

ماتریس  $V$  پایین مثلثی با قطر اصلی ۱ است

ماتریس  $D$  قطری است

$$\phi[i, j] = \sum_{k=1}^j V_{ik} d_k V_{jk} \quad 1 \leq j < i \quad \rightarrow \quad V_{ij} d_j = \phi[i, j] - \sum_{k=1}^{j-1} V_{ik} d_k V_{jk} \quad 1 \leq j < i$$

$$\phi[i, i] = \sum_{k=1}^i V_{ik} d_k V_{ik} \quad \rightarrow \quad d_i = \phi[i, i] - \sum_{k=1}^{i-1} V_{ik}^2 d_k, \quad i \geq 2 \quad \rightarrow \quad d_1 = \phi[1, 1]$$

# تحلیل LPC: محاسبه ضرایب ...

## روش کواریانس

$$\left| \begin{array}{l} \Phi \mathbf{a} = \boldsymbol{\psi} \\ \Phi = \mathbf{V} \mathbf{D} \mathbf{V}^t \end{array} \right. \rightarrow \left| \begin{array}{l} \mathbf{V} \mathbf{Y} = \boldsymbol{\psi} \\ \mathbf{Y} = \mathbf{D} \mathbf{V}^t \mathbf{a} \end{array} \right. \rightarrow \mathbf{V}^t \mathbf{a} = \mathbf{D}^{-1} \mathbf{Y}$$

- با داشتن  $\mathbf{V}$ , مقدار  $\mathbf{Y}$  (به صورت بازگشتی) قابل محاسبه است



$$Y_i = \psi_i - \sum_{j=1}^{i-1} V_{ij} Y_j , \quad 2 \leq i \leq p \quad \rightarrow \quad Y_1 = \psi_1$$

$$\left| \begin{array}{l} a_i = Y_i / d_i - \sum_{j=i+1}^p V_{ji} a_j , \quad 1 \leq i < p \\ a_p = Y_p / d_p \end{array} \right. \quad \bullet \quad \text{با داشتن } \mathbf{Y}, \text{ ضرایب } \mathbf{a} \text{ بدست می‌آید}$$

## تحلیل LPC: تحلیل طیفی ...

$$H(e^{j\omega}) = \frac{G}{1 - \sum_{k=1}^p a_k e^{-j\omega k}} = \frac{G}{A(e^{j\omega})}$$

- تحلیل طیفی با ... LPC
- یک فیلتر تمام-قطب (IIR)
- با رسم  $H(e^{j\omega})$  قله‌هایی را در ریشه‌های مخرج داریم




# تحلیل LPC: تحلیل طیفی ...

## ○ انتخاب مرتبه P


- مدل تمام-قطب مادامی که از تعداد قطب‌های زیاد استفاده می‌کند، تقریب خوبی دارد
  - حتی برای واژه‌ای خیشومی که صفر هم دارد
- به طور میانگین طیف گفتار شامل یک قطب در هر کیلو هرتز
- در عمل  $P = F_S + (2 \text{ or } 4)$  تقریب خوبی است

افزایش مرتبه = جزئیات بیشتر در طیف



$F_S$  بسامد نمونه‌گیری بر حسب کیلوهرتز

افزایش مرتبه = کاهش خطأ




# تحلیل LPC: خطای پیش‌بینی . . .

## ○ خطای پیش‌بینی (سیگنال تحریک یا باقی‌مانده)

$$e[n] = x[n] - \tilde{x}[n] = x[n] - \sum_{k=1}^p a_k x[n-k]$$

- گفتار بی‌واک: به‌طور تقریبی باید نوفه سفید باشد (در عمل، این تقریب کاملاً خوب است)
- گفتار واک‌دار: که به‌طور تقریبی باید زنجیره پالسی باشد (در عمل اینگونه نیست)
- گفتار واقعی کاملاً دوره‌ای نیست (یک مؤلفه تصادفی نیز دارد) و فرض تمام-قطب در مجموع معتبر نیست (صفراها با فیلتر LPC مدل‌سازی نشده)
- تولید گفتار (سنتر) با این روش = گفتار رباتی



می‌بایست زنجیره پالس باشند


## تحلیل LPC: کاربردها ...

- استفاده در کدینگ و سنتز گفتار

- استفاده از ضرایب LP به عنوان ویژگی (در پردازش گفتار)

$$X(e^{j\omega}) = \frac{G}{FT([1, a_1, a_2, \dots, a_p])}$$

- تخمین طیف (پوش طیف) از روی ضرایب LP




- تخمین فرکانس فرمنت‌ها

- قله‌های پوش طیف گفتار

- تخمین فرکانس زیروبمی (Pitch)

- محاسبه سیگنال تحریک (باقي مانده) با فیلتر کردن معکوس




- محاسبه همبستگی و یافته نقطه بیشینه جهت تخمین دوره تناوب آن



## تحلیل LPC: مثال ...

○ یک فریم از واژه /e/ فارسی

سیگنال بعد از ضرب در پنجره 20 میلی ثانیه همینگ





# تحلیل LPC: مثال

نمونه کد

- از سایت بردارید

```

13 FrameLen = 20; % in ms
14 LPCOrder = 10;
15 [SpeechSig,Fs,Bits]=wavread('voiced-e.wav');
16 FrameLen = FrameLen*Fs/1000;
17 SpeechSig=SpeechSig./(1.01*abs(max(SpeechSig))); % Normalize to [-1,1]
18 SpeechSig=SpeechSig(FrameLen+1:2*FrameLen);
19 Win=hamming(FrameLen);
20 SpeechSig=SpeechSig.*Win; % windowing
21 SpeechCorr=xcorr(SpeechSig,SpeechSig);
22 SpeechCorr=SpeechCorr./ (abs(max(SpeechCorr)));
23 SpeechCorr = SpeechCorr(end/2:end);
24
25 % Compute LP coeffs
26 A=SpeechCorr(1:LPCOrder); % P order autocorr
27 r=SpeechCorr(2:(LPCOrder+1));
28 A=toeplitz(A); % Toeplitz autocorr matrix
29 L=-inv(A)*r;
30 LPCoeffs = [1;L]; % this is eq. to LPCoeffs=lpc(SpeechSig,LPCOrder)
31
32 % Compute residuals
33 Residual =conv(SpeechSig,LPCoeffs); % convolution of speech signal and the filter (inve:
34 Residual=Residual(round(LPCOrder/2):length(Residual)-round(LPCOrder/2)-1);
35
36 % Pitch Estimation from Residuals
37 ResidualCorr=xcorr(Residual,Residual); %auto-correlation
38 ResidualCorr = ResidualCorr(end/2:end);
39 ResidualCorr=ResidualCorr./ (abs(max(ResidualCorr)));
40 MinPitch=20; %min pitch period
41 MaxPitch=160; % max pitch
42 ResidualCorrInterval=ResidualCorr(MinPitch:MaxPitch);
43 [PitchVal,PitchLoc]=max(ResidualCorrInterval); % find the (second) peak
44 PitchPeriod=MinPitch+PitchLoc;
45 PitchFreq=(1./PitchPeriod)*Fs;
46
47 % Formant Estimation from LP Spectrum
48 LPSpec=abs(fft(LPCoeffs,Fs)); %Calculate LP Spectrum (taking FFT from LP coeffs)
49 LPSpec=LPSpec.^(-1);
50 LPSpec=20*log10(LPSpec);

```

## تحلیل ... LPC

### روش‌های معادل

- بسامدهای طیفی خط (LSF: Line Spectral Frequencies)
  - رایج در کدینگ
- ضرایب بازتاب (Reflection Coefficients)
- نسبت‌های لگاریتم-مساحت (Log-Area Ratios)
- ریشه‌های چندجمله‌ای (Roots of Polynomial)

## LPC تحلیل

$$x[n] = \sum_{i=1}^p a_i x[n-i] + \sum_{j=0}^q a_j e[n-j]$$

### ○ مدل عمومی تخمین

- تخمین نمونه زمان  $n$  بر حسب  $p$  نمونه قبلي ( $x$ ) خودش و  $q$  نمونه ورودی ( $e$ )

- اگر  $q=0$ : تخمین فقط بر حسب نمونه‌های قبلي خودش = مدل AR: Auto-Regressive

- مدل تمام قطب

- اگر  $p=0$ : تخمین فقط بر حسب نمونه‌های ورودی = مدل MA: Moving Average

- مدل تمام صفر

- اگر  $p \neq 0$  و  $q \neq 0$ : تخمین بر حسب نمونه‌های قبلي و ورودی = مدل ARMA


- مدل ترکیبی صفر-قطب

## تحلیل کپستروم ...

### ○ ایده تحلیل کپستروم (Cepstrum)

• در سال ۱۹۶۴ توسط (Healy, John Tukey) Bogert

• تخمین فیلتر ( $h$ ) و منبع ( $e$ ) در مدل منبع-فیلتر با جدای کردن آنها از همدیگر




• با داشتن این رابطه، می‌توان فیلتر ( $h$ ) و منبع ( $e$ ) را بدست آورد

• کپستروم (Cepstrum) = یک تبدیل همریخت برای تبدیل کانولوشن به جمع

## تحلیل کپسٹروم ...

- تفکیک فیلتر ( $h$ ) و منبع ( $e$ ) با تبدیل هم‌ریخت



- در صورتی که بخواهیم  $e[n]$  را تخمین بزنیم، از فیلتر  $[n]$  زیر استفاده می‌کنیم

$$l[n] = \begin{cases} 1 & |n| \geq N \\ 0 & |n| < N \end{cases}$$


- بخشی از خروجی تبدیل هم‌ریخت معادل فیلتر و بخش دیگر معادل منبع است

## تحلیل کپستروم ...

### ○ تعریف کپستروم حقیقی

- معکوس تبدیل فوریه لگاریتم دامنه تبدیل فوریه

$$c[n] = \mathcal{F}^{-1}\{\log|\mathcal{F}\{x[n]\}|\}$$




## تحلیل کپستروم ...

### ○ تعریف کپستروم موهومی

$$\hat{x}[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln X(e^{j\omega}) e^{j\omega n} d\omega$$

$$\hat{X}(e^{j\omega}) = \ln X(e^{j\omega}) = \ln |X(e^{j\omega})| + j\theta(\omega)$$

$$\theta(\omega) = \arg[X(e^{j\omega})]$$






## تحلیل کپستروم ...

### ◦ لیفتر کردن (Lifting) ...

- جدا کردن منبع از فیلتر با **فیلتر کردن کپستروم**

### (Low-time lifting) لیفتر کردن زمان پایین (Low-time lifting)


- حفظ بخش ابتدایی کپستروم



$$l[n] = \begin{cases} 1 & |n| < N \\ 0 & |n| \geq N \end{cases}$$

مقدار 15 یا 20

- محاسبه فرمنت‌ها: گرفتن تبدیل فوریه (و بدست آوردن لگاریتم طیف)، و یافتن نقاط بیشینه






## تحلیل کپستروم ...

### ... (Liftering) لیفتر کردن

• لیفتر کردن زمان بالا (High-time liftering)


◦ بخش انتهایی کپستروم = سیگنال تحریک



$$l[n] = \begin{cases} 1 & |n| \geq N \\ 0 & |n| < N \end{cases}$$

مقدار 15 یا 20



◦ محاسبه فرکانس زیروبمی (pitch): یافتن نقطه بیشینه روی کپستروم لیفتر شده







## تحلیل کپستروم: مثال . . .

- برای سیگنال واکدار

- یک فریم از واژه /e/ فارسی



## تحلیل کپستروم: مثال ..









- برای سیگنال واکدار
- یک فریم از واچ /e/ فارسی

گرفتن تبدیل فوریه  
(محاسبه لگاریتم طیف) و  
یافتن نقاط بیشینه

## تحلیل کپسکتروم: مثال . . .

- برای سیگنال بی‌واک

- یک فریم از واچ /f/ فارسی





## تحلیل کپسکتروم: مثال

نمونه کد

- از سایت بردارید

```

11 FrameLen = 20; % in ms
12 LifterCutOff = 20; % cut off of the liftering, 15 or 20
13 [SpeechSig,Fs,Bits]=wavread('voiced-e.wav');
14
15
16 FrameLen = FrameLen*Fs/1000;
17 SpeechSig=SpeechSig./(1.01*abs(max(SpeechSig))); % Normalize to [-1,1]
18 SpeechSig=SpeechSig(FrameLen+1:2*FrameLen);
19 Win=hamming(FrameLen);
20 SpeechSig=SpeechSig.*Win; % windowing
21 Cepstrum=log(abs(fft(SpeechSig)));
22 Cepstrum=ifft(Cepstrum);
23
24 % Liftering (High-time)
25 Cepstrum2=Cepstrum(1:length(Cepstrum)/2)'; % the cepstrum is symmetric
26 LifterHigh=zeros(1,length(Cepstrum2));
27 LifterHigh(LifterCutOff:length(LifterHigh))=1;
28 CepstrumHighTime=real(Cepstrum2.*LifterHigh);
29
30 % Liftering (Low-time)
31 LifterLow=zeros(1,length(Cepstrum2));
32 LifterLow(1:LifterCutOff)=1;
33 CepstrumLowTime=real(Cepstrum2.*LifterLow);
34
35 % Pitch estimation
36 [PitchVal,PitchLoc]=max(CepstrumHighTime);
37 PitchPeriod=PitchLoc;
38 PitchFreq=(1/PitchPeriod)*Fs;
39
40 % Formant estimation
41 CepstrumLowTime2=CepstrumLowTime(1:LifterCutOff);
42 CepstrumLowTime2Spec=fft(CepstrumLowTime2,Fs); % spectrum of low-time cepstrum
43 CepstrumLowTime2Spec2=CepstrumLowTime2Spec(1:Fs/2); % spectrum is symmetric
44 CepstrumLowTime2Spec2=real(CepstrumLowTime2Spec2);
45 k=1;
46 for i=2:length(CepstrumLowTime2Spec2)-1
47 if (CepstrumLowTime2Spec2(i-1)<CepstrumLowTime2Spec2(i)) & (CepstrumLowTime2Spec2(i+1)<Ce

```

## تحليل کپسکتروم

- در نظر گرفتن لگاریتم طیف به عنوان شکل موج سیگنال
- استفاده به عنوان ویژگی: نمایش فشرده پوش طیف
  - ضرایب مستقل از هم
- توانایی بالا در تشخیص واکداری و فرکانس Pitch
- نام‌گذاری: معکوس کردن هجای اول کلمات معادل (Spectrum) در مقابل اسپکتروم (طیف) (Cepstrum)
  - کپسکتروم (Cepstrum)
  - حوزه Quefrency در مقابل Frequency
  - لیفتر کردن (Lifting) در مقابل فیلتر کردن (Filtering)



## روش ... MFCC

### ○ ضرایب کپسکتروم در مقیاس مل

MFCC: Mel-Frequency Cepstral Coefficients •

• در سال ۱۹۸۰ توسط Mermelstein و Davis

• پرکاربردترین ویژگی گفتار در سیستم‌های تشخیص گفتار

• در واقع نوعی کپسکتروم حقیقی است (با تفاوت‌های زیر)


◦ تبدیل فوریه مورد استفاده در آن FFT است


◦ تبدیل معکوس فوریه DCT است

◦ یک مقیاس غیرخطی (مل) فرکانسی در آن استفاده می‌شود = شبیه‌سازی رفتار سیستم شنوایی

# روش ... MFCC

## مراحل








# روش ... MFCC


## ۱- فریم‌گذاری

- طول هر فریم از کاربرد دیگر متفاوت است (معمولاً بین ۱۰ تا ۵۰ میلی ثانیه)
- فریم‌های متوالی با همدیگر همپوشانی (Overlap) دارند (۰.۷۵٪ تا ۰.۲۵٪ طول فریم)
- برای سیگنالی با نرخ نمونه برداری ۱۶kHz و فریم‌های ۲۰ms: بردار  $N=320$  بعدی

## ۲- فیلتر پیش تاکید (Pre-Emphasis Filter)

- فیلتر بالاگذار برای تقویت فرکانس‌های (فرمنت‌های) بالا
- حذف اثرات طیفی حنجره (دو قطب) و لبها (یک صفر)
- مقدار معمول برای ضریب پیش تاکید  $\alpha=0.95$
- $0.9 \leq \alpha \leq 1.0$
- بردار  $N=320$  بعدی






## روش ... MFCC

### ۳- پنجره‌گذاری

- معمولاً پنجره همینگ-بردار  $N=320$  بُعدی




### ۴- محاسبه (توان) طیف


$$X_a[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi nk/N}, \quad 0 \leq k < N$$

- استفاده از FFT

چون سیگنال حقیقی است، متقارن است، کافیست نصف آن را نگه داریم




- بردار  $N=160$  بُعدی



## روش ... MFCC

### ۵- بانک فیلتر در مقیاس مل . . .


- مدل کردن حساسیت گوش انسان نسبت به حوزه‌های مختلف فرکانس
- گوش به اطلاعات فرکانس پایین ارزش بیشتری می‌دهد
- عملکرد گوش برای فرکانس‌های کمتر از یک کیلو هرتز، خطی و برای فرکانس‌های بالاتر لگاریتمی است



$$S[m] = \left[ \sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k] \right], \quad 0 \leq m < M$$

- ضرب فیلترها در طیف و محاسبه انرژی هر فیلتر


تعداد فیلترها



# روش ... MFCC

## ۵- بانک فیلتر در مقياس مل

- فیلترها



Index	Mel Scale	
	Center Freq. (Hz)	BW (Hz)
1	100	100
2	200	100
3	300	100
4	400	100
5	500	100
6	600	100
7	700	100
8	800	100
9	900	100
10	1000	124
11	1149	160
12	1320	184
13	1516	211
14	1741	242
15	2000	278
16	2297	320
17	2639	367
18	3031	422
19	3482	484
20	4000	556
21	4595	639
22	5278	734
23	6063	843
24	6964	969

برای 8 kHz

$$H_m[k] = \begin{cases} 0 & k < f[m-1] \\ \frac{(k - f[m-1])}{(f[m] - f[m-1])} & f[m-1] \leq k \leq f[m] \\ \frac{(f[m+1] - k)}{(f[m+1] - f[m])} & f[m] \leq k \leq f[m+1] \\ 0 & k > f[m+1] \end{cases}$$

FFT اندازه

$$f[m] = \left( \frac{N}{F_s} \right) B^{-1} \left( B(f_l) + m \frac{B(f_h) - B(f_l)}{M+1} \right)$$


تعداد فیلترها

$$B(f) = 1125 \ln(1 + f / 700)$$

بیشینه فرکانس

کمینه فرکانس

$$B^{-1}(b) = 700 (\exp(b/1125) - 1)$$



## روش ... MFCC

### ۶- تبدیل لگاریتم

- بردار ویژگی:  $N=24$  بعدی

$$S[m] = \ln \left[ \begin{array}{c} S[m] \end{array} \right]$$

### ۷- تبدیل کسینوسی گسته (DCT: Discrete Cosine Transform)

- معادل معکوس تبدیل فوریه در کپستروم حقیقی


$$c[n] = \sum_{m=0}^{M-1} S[m] \cos\left(\pi n(m+1/2)/M\right) \quad 0 \leq n < M$$

معمولاً این مقدار مقدار  
نصف تعداد فیلترهاست

- کاهش ابعاد بردار ویژگی:  $N=12$  بعدی

- کاهش ابعاد بردار ویژگی از ۳۲۰ به ۱۲!





## روش ... MFCC

### MFCC مشتقات ضرایب

- ضرایب MFCC فقط شامل اطلاعات استاتیک هر فریم است
- اطلاعات پویا و اثر فریم‌های مجاور (به دلیل غیر ایستان بودن گفتار) نیز لازم است
- محاسبه مشتقات زمانی از روی فریم‌های مجاور

#### مشتق اول(دلتا) و مشتق دوم(دلتا-دلتا)

$$\Delta C[n] = \sum_{i=-k}^k (i.C[n+i]) / \sum_{i=-k}^k i^2$$

- روش رگرسیون خطی  $k$  فریم قبل و  $k$  فریم بعد

$$\Delta^2 C[n] = \frac{2 \left\{ \left( \sum_{i=-k}^k i^2 \right) \left( \sum_{i=-k}^k C[n+i] \right) - (2k+1) \sum_{i=-k}^k (i^2 C[n+i]) \right\}}{\left( \sum_{i=-k}^k i^2 \right)^2 - (2k+1) \left( \sum_{i=-k}^k i^4 \right)}$$


مقدار معمول 1 (یا 2)

$$\Delta C[n] = C[n+k] - C[n-k]$$

- روش تفاضل (ساده‌تر)

$$\Delta^2 C[n] = \Delta C[n+k] - \Delta C[n-k] = C[n+2k] - 2C[n] + C[n-2k]$$

- اضافه کردن مشتق اول و دوم به بردار ویژگی‌ها: اندازه بردار ویژگی:  $N=3*12$  بُعدی



## روش ... MFCC

### ○ نرمال‌سازی میانگین

- تفاضل میانگین کپسترال (CMS: Cepstral Mean Subtraction)
- نرمال‌سازی میانگین کپسترال (CMN: Cepstral Mean Normalization)

- یکی از رایج‌ترین، ساده‌ترین و مؤثر‌ترین روش‌های نرمال‌سازی
- برای حذف اثر کanal (مثل خط تلفن، تنوع میکروفون و ...) و نویز‌های کانوالوشنده
- متوسط بردارهای ویژگی کپسترال (در طول چند صد فریم) محاسبه و سپس این مقدار میانگین از هر یک از بردارها کم می‌شود
- نویز کانوالوشنده در حوزه زمان = ضرب شونده در حوزه طیف = جمع شونده در حوزه کپسترال

$$\mathbf{C}[k] = \mathbf{C}[k] - \boldsymbol{\mu}$$

$$\boldsymbol{\mu} = \frac{1}{K} \sum_{k=1}^K \mathbf{C}[k]$$

بردار ویژگی‌های MFCC

## روش MFCC


- تبدیلی هم‌ریخت نیست

- مگر اینکه جای لگاریتم گرفتن و محاسبه انرژی فلیتر بانک عوض شود

$$S[m] = \ln \left[ \sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k] \right], \quad 0 \leq m < M \quad \rightarrow \quad S[m] = \sum_{k=0}^{N-1} \ln \left( |X_a[k]|^2 H_m[k] \right) \quad 0 \leq m < M$$

- اما تقریبی از یک تبدیل هم‌ریخت است

- مزیت محاسبه به ترتیب بیان شده در MFCC مقاوم بودن به نویز در تخمین طیف



- برای تشخیص گفتار بسیار مناسب است

- در سایر کاربردها هم کارایی خوبی دارد!

# فرکانس زیروبمی (Pitch) ...

## ○ کاربردها

- ویژگی بسیار مهمی در سنتز گفتار برای مدل‌سازی نوا
- استفاده در زبان‌های زبان‌های (Tonal) در تشخیص گفتار
  - تغییر زیروبمی سبب تغییر معنی می‌شود
- استفاده به عنوان یک ویژگی (در تشخیص گوینده)
  - در مدل منبع-فیلتر یکی از پارامترهای تولید گفتار است

## ○ روش‌های تشخیص

- مبتنی بر کپستروم
- خودهمبستگی (بیشینه مقدار خودهمبستگی به غیر از نقطه صفر)
- همبستگی متقطع نرمال شده (Normalized Cross-Correlation)



## فرکانس زیروبمی (Pitch) ...

### روش خودهمبستگی ...

- بیشترین مقدار تابع خودهمبستگی در قاب (فریم)
- نقطه  $m=0$  (شروع سیگنال) بیشینه‌ی مطلق تابع خودهمبستگی است و باید آن را نادیده گرفت.
- تعداد نمونه ها  $N$

$$\hat{R}[m] = \frac{1}{N} \sum_{n=0}^{N-1-|m|} w[n] \mathbf{x}[n] w[n+|m|] \mathbf{x}[n+|m|]$$





- دوره‌های زیروبمی می‌توانند حداقل ۴۰ هرتز (برای صدای مردانه با زیروبمی بسیار پایین) و حداقل ۶۰۰ هرتز (برای صدای زنانه یا کودکانه با زیروبمی بسیار بالا) باشند
- جستجو برای بیشینه درون یک بازه صورت می‌گیرد



- مقادیر زیروبمی در مناطق بی‌واک تصادفی هستند


# فرکانس زیروبمی (Pitch) ...

روش خودهمبستگی



فریم اصلی و نسخه جابجا شده آن

## فرکانس زیروبمی (Pitch)



- روش همبستگی متقاطع نرمال شده
- مشابه روش خودهمبستگی با مقداری بهبود

$$\alpha_t(T) = \cos(\theta) = \frac{\langle \mathbf{x}_t, \mathbf{x}_{t-T} \rangle}{\|\mathbf{x}_t\| \|\mathbf{x}_{t-T}\|} = \frac{\sum_{n=-N/2}^{N/2-1} x[t+n]x(t+n-T)}{\sqrt{\sum_{n=-N/2}^{N/2-1} x^2[t+n] \sum_{m=-N/2}^{N/2-1} x^2[t+m+T]}}$$

- این تخمین غیراریب است (روش خودهمبستگی اریب دارد)
- واریانس پایین‌تری از تخمین خودهمبستگی دارد
- برخلاف روش خودهمبستگی، طول پنجره می‌تواند کمتر از دوره زیروبمی باشد
- بهطوری‌که فرض مانا بودن صحیح‌تر است و وضوح زمانی بیشتری دارد
- ردیابی زیروبمی با این روش معمولاً بهتر از خودهمبستگی هستند اما مستلزم محاسبات بیشتری هستند