

Processamento de Sinal

Conceitos, Métodos e Aplicações

**Texto Tutorial da Disciplina:
APSI - LEEC**

J.P. Marques de Sá – jmsa@fe.up.pt
Faculdade de Engenharia da Universidade do Porto
© 2001 J.P. Marques de Sá

Índice

4.3	Descrições Tempo-Frequência	3
4.3.1	Motivação	3
4.3.2	Transformada de Fourier Variante no tempo	4
4.3.3	Transformada de ôndulas	13
4.3.4	Transformada de Wigner.....	25

4.3 Descrições Tempo-Frequência

4.3.1 Motivação

$$x(t) \Leftrightarrow T_x(t, f)$$

Análise de sinais determinísticos variantes no tempo ou estocásticos não-estacionários.

Duas classes de métodos:

- Linear

$$x(t) = ax_1(t) + bx_2(t) \Rightarrow T_x(t, f) = aT_{x_1}(t, f) + bT_{x_2}(t, f)$$

Exemplos:

Transformada de Fourier variante no tempo

Transformada de ondas

...

- Quadrático

$$x(t) = ax_1(t) + bx_2(t) \Rightarrow$$

$$T_x(t, f) = |a|^2 T_{x_1}(t, f) + |b|^2 T_{x_2}(t, f) + ab^* T_{x_1 x_2}(t, f) + a^* b T_{x_2 x_1}(t, f)$$

Exemplos:

Transformada de Wigner

...

4.3.2 Transformada de Fourier Variante no tempo

Ideia-chave: Multiplicar o sinal por uma janela corrente no tempo.

$$X(n, \lambda) = \sum_{m=-\infty}^{\infty} x(n+m)w(m)e^{-j\lambda m}$$

Temos a versão discreta da Transformada de Fourier variante no tempo, também designada por STFT ("Short Time Fourier Transform"). A representação de STFT é chamada *espectrograma*.

Exemplo:

Chirp linear.

$$x(n) = \sin(w_0 n^2)$$




Figura 4.24. Cirp linear com $f_0 = 0.4 \times 10^{-3}$ (512 amostras) e uma janela de 64 amostras.

Frequência instantânea de $\sin(\varphi(n))$: $\frac{\partial\varphi(n)}{\partial n} = 2\pi f_0 n = 0.8\pi 10^{-3} n$.

Análise com uma janela de Kaiser de 64 amostras e $\beta = 3.5363$.




Figura 4.25. Espectrograma do chirp linear. A inclinação da recta que passa pelos máximos corresponde à frequência instantânea.




Figura 4.26. Transformadas de Fourier correspondentes às várias translações da janela de Kaiser.

A STFT é invertível se $w(0) \neq 0$:

$$x(n) = \frac{1}{2\pi w(0)} \int_0^{2\pi} X(n, \lambda) d\lambda$$

Usando $m' = n + m$, temos:

$$X(n, \lambda) = \sum_{m'=-\infty}^{\infty} x(m') w(-(n - m')) e^{-j\lambda(n-m')}$$

Logo:

$$X(n, \lambda) = x(n) \otimes h_\lambda(n) \quad e \quad h_\lambda(n) = w(-n)e^{j\lambda n}$$

Na versão DFT, calculada com N amostras, temos:

$$H_k(\omega) = W\left(e^{j[2\pi k / N - \omega]}\right)$$

Podendo-se obter a STFT a partir de um banco de N filtros.




Figura 4.27. Obtenção da STFT por um banco de filtros.

Influência da largura da janela:

- Largura reduzida: boa resolução no tempo e má nas frequências. No limite, a janela tem apenas uma amostra, $w(n) = \delta(n)$, com espectro constante, não permitindo resolver nas frequências.
- Largura ampla: boa resolução nas frequências e má no tempo. No limite, a janela é constante, $w(n) = 1$, não permitindo resolver no tempo.

Princípio da incerteza:

Dado o Teorema do escalamento:

$$af(at) \Leftrightarrow F\left(\frac{\omega}{a}\right)$$

Então, nenhuma função pode ter uma resolução arbitrariamente boa simultaneamente no tempo e na frequência.

Usando como medidas de duração no tempo e na frequência:

$$d^2 = \frac{1}{E} \int_{-\infty}^{\infty} t^2 |f(t)|^2 dt; \quad D^2 = \frac{1}{2\pi E} \int_{-\infty}^{\infty} \omega^2 |F(\omega)|^2 d\omega$$

sendo E a energia do sinal: $E = \int_{-\infty}^{\infty} |f(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |F(\omega)|^2 d\omega$

Prova-se que:

$$\text{Se } \sqrt{t}f(t) \rightarrow 0 \text{ com } |t| \rightarrow \infty, \text{ então } Dd \geq 1/2$$

A igualdade é atingida apenas no caso da curva normal: $f(t) = Ae^{-\alpha t^2}$

Exemplos:

a) ECG amostrado a 500 Hz.




Figura 4.28. ECG amostrado a 500 Hz, com indicação de vários componentes de onda.

Análise no Matlab:

```
specgram(x,512,500,kaiser(256,3.5),250)
specgram(x,256,500,kaiser(64,3.5),60)
```

```
specgram(x,256,500,kaiser(128,3.5),120)
specgram(x,256,500,kaiser(32,3.5),20)
```




Figura 4.29. Espectrogramas do ECG para uma largura de janela de 256, 128, 64 e 32 amostras.

Notar a boa resolução no tempo e na frequência para 64 amostras, com a detecção dos componentes de onda de maior frequência, ondas Q, R.

b) Análise de sinais de voz

Frase "Boa tarde" amostrado a 4009 Hz; 2251 amostras.




Figura 4.30. Sinal de voz correspondente à frase "Boa tarde".




Figura 4.31. Espectrograma do sinal anterior (Matlab: `specgram(x, 256, 4009, hanning(256), 250)`). A transição entre fonemas é visível.

4.3.3 Transformada de ôndulas

Ideia-chave: em vez de avaliarmos a semelhança do sinal com uma sinusóide a múltiplas frequências, avaliamos a semelhança com uma "ôndula" a múltiplas escalas.

Transformada contínua de ôndulas (CWT):

$$W(\tau, a) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{|a|}} \psi^* \left(\frac{t - \tau}{a} \right) dt$$

O parâmetro a é um factor de escala, de dilatação (quanto maior a , mais dilatada é a ôndula).




Figura 4.32. Exemplo de duas ôndulas, a ôndula mãe para $a=1$ e outra comprimida para metade, e o resultado da sua aplicação a um sinal. Notar a descrição proporcionada pelas duas ondas.

A transformada de ôndulas preserva translações e escalamentos no tempo:

- $\tilde{x}(t) = x(t - t_0) \Rightarrow W_{\tilde{x}}(\tau, a) = W_x(\tau - t_0, a)$
- $\tilde{x}(t) = \sqrt{|s|}x(st) \Rightarrow W_{\tilde{x}}(\tau, a) = W_x(s\tau, \frac{a}{s})$

Não preserva, contudo, translações na escala.

Note-se que a escala está em correspondência inversa com a frequência: quanto maior a escala, menor a frequência e vice-versa. De facto, é possível escrever a CWT na forma:

$$W(\tau, f) = \int_{-\infty}^{\infty} x(t) \sqrt{\frac{f}{f_0}} \psi^* \left(\frac{f}{f_0} (t - \tau) \right) dt$$

sendo ψ , a ôndula mãe, uma função ou complexa do tipo passa-banda tendo f_0 como frequência central.

Também é possível escrever:

$$W(\tau, a) = \int_{-\infty}^{\infty} x(t) \psi_{\tau, a}^*(t) dt \quad \text{com} \quad \psi_{\tau, a}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t - \tau}{a} \right)$$

O factor $1/\sqrt{|a|}$ assegura que todas as ôndulas têm a mesma energia.

Notar em particular que $\psi_{0,1}(t) = \psi(t)$ é a ôndula mãe.

A transformada inversa de ôndulas é dada por:

$$x(t) = \frac{1}{C} \int_{a=-\infty}^{\infty} \int_{\tau=-\infty}^{\infty} \frac{1}{|a|^2} W(\tau, a) \psi_{\tau, a}(t) da d\tau$$

A CWT proporciona uma representação redundante, já que não necessitamos de todo o suporte de $W(\tau, a)$ para recuperar $x(t)$.

De facto, obtém-se uma representação não redundante dilatações e translações múltiplos de 2:

$$x(t) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} d(k, l) 2^{-k/2} \psi(2^{-k} t - l)$$

sendo $d(k, l)$ a *transformada discreta de ôndulas* (sinais reais).

Temos, agora, uma *representação diádica*.




Figura 4.33. Representação diádica da transformada discreta de ondas.

Notar que:

- A largura das "caixas" é maior quando a altura é menor e vice-versa.
- A área das "caixas" é constante.

A transformada discreta de ondas tem assim um comportamento mais adequado que a STFT face ao princípio da incerteza.

A transformada discreta de ôndulas (DWT) é definida como:

$$d(k, l) = \frac{1}{2^k} \int_{2^{k_l}}^{2^{k(l+1)}} x(t) \psi(2^{-k} t - l) dt$$

Suponhamos que as ôndulas satisfazem as seguintes condições:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0$$

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt = 1$$

$$\langle \psi(t), \psi(t - n) \rangle = \delta(n)$$

$$\langle \psi(t), \phi(t - n) \rangle = 0, \quad \text{com } \phi(t) = \begin{cases} 1 & 0 \leq t \leq 1 \\ 0 & \text{outros } t \end{cases}$$

Então os coeficientes da DWT podem obter-se através da decomposição do sinal em:

- *Aproximações:* $x_k(t) = \frac{1}{2^k} \int_{2^{k_l}}^{2^{k(l+1)}} x(\tau) \psi(\tau, k) d\tau$

- *Detalhes:* $g_k(t) = x_{k-1}(t) - x_k(t)$




Figura 4.34. Decomposição do sinal anterior em aproximação e detalhe.

A decomposição é realizada usando filtros correspondentes às ondas, com decimação por 2.




Figura 4.35. Decomposição de um sinal em aproximação cA_k e detalhe cD_k .

A decomposição pode ser iterada em vários níveis até atingir um nível em que os detalhes só representam ruído branco.




Figura 4.36. Decomposição multinível (3 níveis) de um sinal em aproximações e detalhes.

A reconstrução é feita "bottom-up" usando as interpolações duais das decimações.

Notar que:

- É necessário escolher a ôndula, ordem e nível de decomposição adequado ao problema.
- Na escolha da ôndula é necessário ter em conta as suas propriedades (ver referências)

Exemplos:

a) Análise de sinais

Análise do ECG: decomposição nas ondas componentes.




Figura 4. 37. Aproximações e detalhes na análise do ECG usando a ôndula coiflet de ordem 3. Notar que o detalhe d3 só ocorre no segmento QR do sinal.

b) Remoção de ruído em sinais

Remoção de ruído de alta frequência do ECG.

Método: fixação de limitações nos detalhes.




Figura 4.38. Remoção e limitação de detalhes para o ECG anterior.




Figura 4. 39. ECG original e reconstruído.

c) Detecção de descontinuidades

$$x(n) = \begin{cases} \sin(2\pi 0.01 n), & 0 \leq n \leq 125 \\ \sin(2\pi 0.011 n - 0.9), & 126 \leq n \leq 250 \end{cases}$$




Figura 4.40. Detalhes mostrando uma descontinuidade imperceptível (ôndula coif3; 3 níveis).

d) Remoção de evoluções lentas ("trends")




Figura 4.41. Sinal ECG original (a) e sinal reconstruído (b) usando só os detalhes de uma decomposição em 9 níveis (c), usando a ôndula Daubechies db5.

4.3.4 Transformada de Wigner

Transformação quadrática: adequada à representação tempo-frequência da energia de um sinal, logo, adequada à representação de sinais estocásticos não-estacionários.

Transformada de Wigner:

$$W(t, f) = \int_{\tau=-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right)x^*\left(t - \frac{\tau}{2}\right)e^{-j2\pi f\tau} d\tau = \int_{\nu=-\infty}^{\infty} X\left(f + \frac{\nu}{2}\right)X^*\left(f - \frac{\nu}{2}\right)e^{j2\pi\nu t} d\nu$$

Propriedades:

$$\int_f W(t, f)df = |x(t)|^2$$

$$\int_t W(t, f)dt = |X(f)|^2$$

$$W^*(t, f) = W(t, f)$$

$$x(t - t_0) \Rightarrow W(t - t_0, f)$$

$$x(t)e^{j2\pi f_0 t} \Rightarrow W(t, f - f_0)$$

$$\sqrt{|a|}x(at) \Rightarrow W\left(at, \frac{f}{a}\right)$$

Exemplo:

Segmentos de EEG de viglância e sono com 500 amostras.




Figura 4.42. Transformada de Wigner do EEG de viglância.




Figura 4.43. Transformada de Wigner do EEG de sono.

Bibliografia

- Cadzow JA (1982) Spectral Estimation: An Overdetermined Rational Model Equation Approach. Proc. IEEE, 70:907-938.
- Cohen L (1989) Time-Frequency Distributions-A Review. Proc. IEEE, 77:941-981.
- Hlawatsch F, Boudreaux-Bartels GF (1992) Linear and Quadratic Time-Frequency Signal Representations. IEEE SP Magazine, April, 21-67.
- Kuc R (1988) Introduction to Digital Signal Processing. Mc Graw-Hill, Inc.
- Lindner DK (1999) Introduction to Signals and Systems. Mc Graw-Hill, Inc.
- Lyons RG (1997) Understanding Digital Signal Processing. Addison Wesley Longman, Inc.
- Oppenheim AV, Schafer RW, Buck JR (1999) Discrete-Time Signal Processing. Prentice-Hall Inc.
- Papoulis A (1984) Signal Analysis. McGraw-Hill, Inc.
- Proakis JG, Manolakis DG (1996) Digital Signal Processing. Principles, Algorithms and Applications. Prentice Hall Int., Inc.
- Rabiner LR, Gold B (1975) Theory and Application of Digital Signal Processing. Prentice-Hall, Inc.
- Rao RM, Bopardikar AS (1998) Wavelet Transforms. Introduction to Theory and Applications. Addison-Wesley.
- Robinson EA (1982) A Historical Perspective of Spectrum Estimation. Proc. IEEE, 70:885-906.
- Schwarz M, Shaw L (1975) Signal Processing: Discrete Spectral Analysis, Detection, and Estimation. McGraw-Hill.