

**MAC0317/MAC5920**

**Introdução ao Processamento de Sinais Digitais**

**Capítulo 5: Janelamento e Localização**

## Seção 5.1 - Visão geral: Não-localidade da DFT

### Exemplo 5.1

Considere dois sinais  $f(t)$  e  $g(t)$  definidos em  $0 \leq t \leq 1$  como

$$f(t) = \frac{1}{2} \sin(2\pi(96)t) + \frac{1}{2} \sin(2\pi(235)t)$$

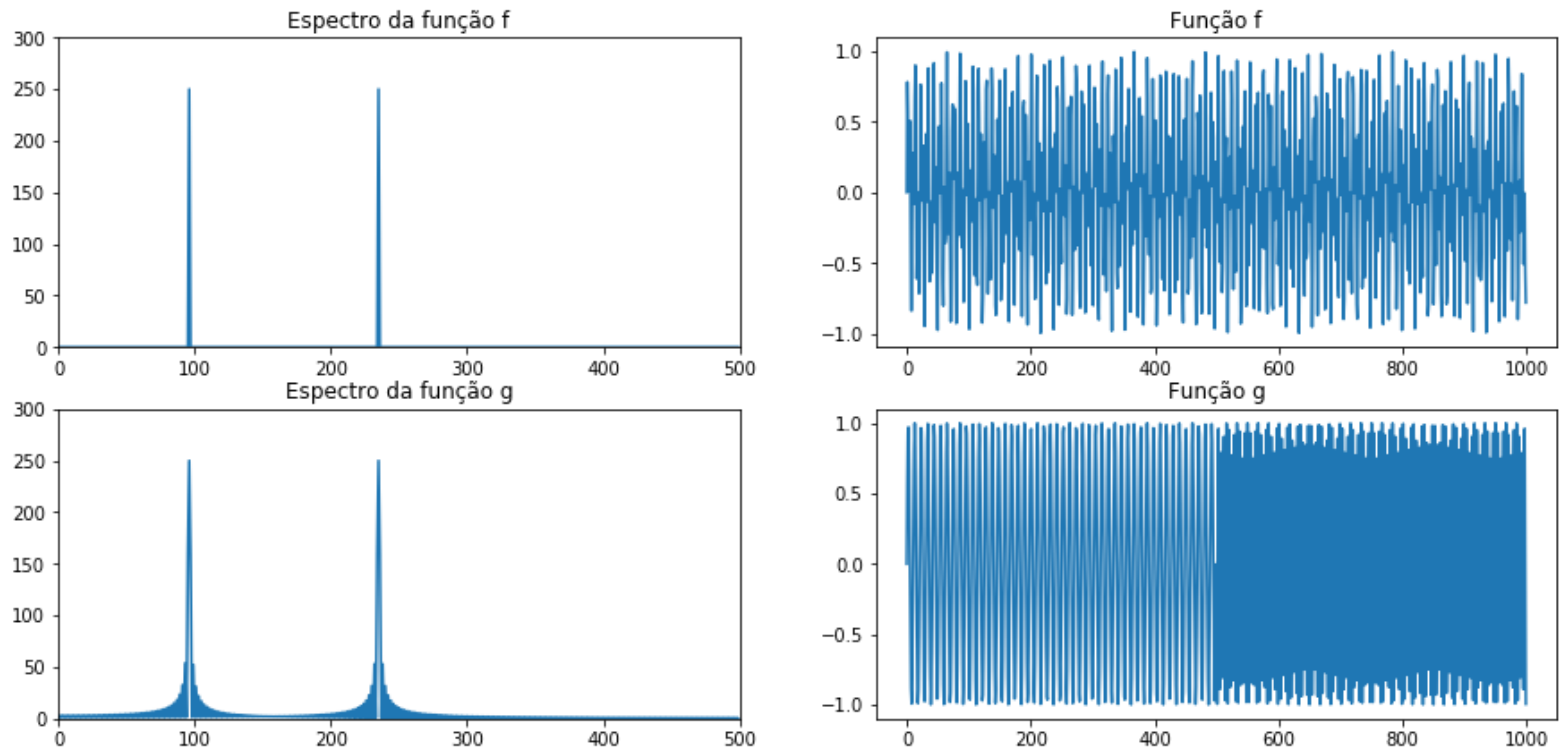
e

$$g(t) = \begin{cases} \sin(2\pi(96)t), & 0 \leq t < \frac{1}{2} \\ \sin(2\pi(235)t), & \frac{1}{2} \leq t \leq 1. \end{cases}$$

Esses sinais são amostrados com taxa  $R = 1000$  Hz e suas DFTs são apresentadas a seguir.

```
In [2]: N = 1000; t = np.linspace(0, 1-1/N, N); f = 0.5*np.sin(2*m.pi*96*t)+0.5*np.sin(2*
m.pi*235*t)
g = np.concatenate( (np.sin(2*m.pi*96*t[0:N//2]), np.sin(2*m.pi*235*t[N//2:N]))
, axis=0)
fig, axes = plt.subplots(2,2, figsize=(15,7)); fig.suptitle("Figura 5.1")
axes[0,0].set_title('Espectro da função f'); axes[0,0].plot( range(N//2) , abs(n
p.fft.fft(f)[0:N//2]) )
axes[0,0].axis([0, 500, 0, 300]); axes[0,1].set_title('Função f'); axes[0,1].plot
(f)
axes[1,0].set_title('Espectro da função g'); axes[1,0].plot( range(N//2) , abs(n
p.fft.fft(g)[0:N//2]) )
axes[1,0].axis([0, 500, 0, 300]); axes[1,1].set_title('Função g'); axes[1,1].plot
(g); plt.show()
```

Figura 5.1



Esse exemplo ilustra a característica de *não-localidade* da DFT: os espectros mostram as componentes senoidais presentes no sinal, mas não permitem distinguir *em que segmentos temporais* do sinal essas componentes estão ativas.

Isso fica claro ao considerarmos que a DFT expressa um sinal  $x$  através da equação de síntese

$$x = \frac{1}{N} \sum_{k=0}^{N-1} X_k E_k,$$

onde  $E_k$  são formas de onda básicas cujo comportamento oscilatório é invariante ao longo de todo o sinal. Ou seja, na equação de síntese *todas as componentes estão presentes o tempo todo e com intensidade constante* ( $|X_k|$ ), já que cada sinal  $X_k E_k$  tem a forma

$$X_k E_k = \left( X_k(E_k)_0, X_k(E_k)_1, \dots, X_k(E_k)_{N-1} \right) = \left( X_k e^{i2\pi k(0)/N}, X_k e^{i2\pi k(1)/N}, \dots, X_k e^{i2\pi k(N-1)/N} \right),$$

sendo que o mesmo coeficiente  $X_k$  está presente durante toda a duração dessa componente de frequência fixa  $k$  (ciclos por  $N$  amostras).





Nesse exemplo em particular é possível investigar como o sinal  $g(t)$  que *alterna* as duas senóides de frequências 96 Hz e 235 Hz pode ser representado pela DFT que considera apenas componentes sem variação de frequência:

- podemos considerar  $g(t) = g^{(1)}(t) + g^{(2)}(t)$  onde
$$g^{(1)}(t) = \sin(2\pi(96)t), \quad 0 \leq t < \frac{1}{2}, \quad g^{(1)}(t) = 0, \quad \frac{1}{2} \leq t \leq 1,$$
$$g^{(2)}(t) = \sin(2\pi(235)t), \quad \frac{1}{2} \leq t \leq 1, \quad g^{(2)}(t) = 0, \quad 0 \leq t < \frac{1}{2},$$
onde  $g^{(1)}$  e  $g^{(2)}$  podem ser vistos como *recortes* do sinal por *janelas* de tamanho  $\frac{N}{2}$ ;
- pela linearidade da DFT, sabemos que  $G_k = G_k^{(1)} + G_k^{(2)}, \forall k$ ;
- o gráfico a seguir mostra como a DFT de  $g$  se decompõe exatamente nas DFTs de  $g^{(1)}$  e  $g^{(2)}$ .

```

In [3]: g1 = g*(t<0.5) # mantém primeira metade do sinal, anula segunda metade
g2 = g*(t>=0.5) # mantém segunda metade do sinal, anula primeira metade
fig, axes = plt.subplots(2,2, figsize=(15,7))
axes[0,0].set_title('Espectro da função $g_1$')
axes[0,0].plot( range(N//2) , abs(np.fft.fft(g1)[0:N//2]) )
axes[0,0].axis([0, 500, 0, 300]);axes[0,1].set_title('Função $g_1$');axes[0,1].
plot(g1)
axes[1,0].set_title('Espectro da função $g_2$')
axes[1,0].plot( range(N//2) , abs(np.fft.fft(g2)[0:N//2]) )
axes[1,0].axis([0, 500, 0, 300]);axes[1,1].set_title('Função $g_2$');axes[1,1].
plot(g2)
plt.show()

```



## Seção 5.2 - Localização por janelamento

Vamos considerar uma generalização do processo de segmentação do sinal visto no exemplo anterior, a partir do produto de  $x \in \mathbb{C}^N$  por uma **janela**, representada por um sinal  $w \in \mathbb{C}^N$ , que seleciona  $M > 0$  amostras a partir de uma amostra inicial  $m \geq 0$ , sendo definida como

$$w_n = \begin{cases} 1, & m \leq n < m + M \\ 0, & \text{caso contrário.} \end{cases}$$

Essa janela permite a construção de um sinal  $y = w.x$  onde '.' denota o produto de Hadamard, ou seja,

$$y_n = w_n x_n, \quad n = 0, 1, \dots, N - 1.$$

O termo *janela* tem relação com a restrição de visualização: no sinal  $y$  só conseguimos observar o conteúdo do sinal  $x$  entre as amostras  $m$  e  $m + M - 1$ . A forma de pulso retangular do sinal  $w$  explica a denominação **janela retangular**.

## Exemplo 5.2

Considere outra vez o sinal  $f \in \mathbb{C}^{1000}$  do exemplo anterior, amostrado a partir de

$$f(t) = \frac{1}{2}\sin(2\pi(96)t) + \frac{1}{2}\sin(2\pi(235)t)$$



com taxa  $R = 1000$  Hz em  $0 \leq t \leq 1$ . Queremos visualizar o conteúdo desse sinal no intervalo  $[m, m + M)$  onde  $m = 100$  e  $M = 50$ . Construiremos duas versões do sinal:

- uma versão *janelada*  $g = w.f \in \mathbb{C}^{1000}$ , obtida pelo produto com a janela retangular  $w \in \mathbb{C}^{1000}$ , definida como  $w_n = 1$ ,  $m \leq n < m + M$  e  $w_n = 0$  caso contrário;
- uma versão *recortada*  $\tilde{f} \in \mathbb{C}^{50}$  definida como  $\tilde{f}_n = f_{m+n}$ ,  $n = 0, 1, \dots, M - 1$ ;
- o restante dessa seção será dedicado a esclarecer a relação entre as DFTs de  $g$  e de  $\tilde{f}$  ilustradas a seguir.



```
In [19]: w = np.zeros(N);w[99:149] = np.ones(50);ftil = w * f
fig, axes = plt.subplots(1, 2, figsize=(15,5));fig.suptitle("Figura 5.2")
axes[0].plot( range(N//2), abs(np.fft.fft(ftil)[0:N//2]) )
axes[0].axis([0, 500, 0, 14]);axes[0].set_title(r"Espectro do sinal janelado $g$
=w.\!f$")
axes[1].plot( range(25), abs(np.fft.fft(ftil[99:149])[0:25]))
axes[1].axis([0, 25, 0, 14]);axes[1].set_title(r"Espectro do sinal recortado
$\tilde{f}$");
```

Figura 5.2



## Seção 5.2.2: Análise do janelamento

Considere a situação ilustrada no último exemplo:

- $x \in \mathbb{C}^N$  é um sinal arbitrário;
- $w \in \mathbb{C}^N$  é uma *janela* definida entre  $m$  e  $m + M - 1$ , ou seja,  $w_n \in \mathbb{C}$ ,  $m \leq n < m + M$  e  $w_n = 0$  caso contrário. A janela retangular  $w_n = 1$ ,  $m \leq n < m + M$  é um exemplo de janela desse tipo, mas não o único que consideraremos;
- $y = w \cdot x \in \mathbb{C}^N$  é o sinal  $x$  *janelado*
- $\tilde{x} \in \mathbb{C}^M$  é o sinal *recortado*  $\tilde{x} = (x_m, \dots, x_{m+M-1})$ .

Para simplificar as equações, vamos considerar que  $M$  divide  $N$  (ou seja, que existe  $q$  inteiro tal que  $N = qM$ ). Vamos investigar a relação entre as DFTs de  $y$  e  $\tilde{x}$  em 3 passos.

## Passo 1: Relação entre $X$ e $Y$

A relação entre as DFTs do sinal original e do sinal janelado é estabelecida a seguir:

### Proposição 5.2.1

Sejam  $x, w \in \mathbb{C}^N$  com DFTs  $X$  e  $W$ , e considere  $y = w.x$  com DFT  $Y$ . Então

$$Y = \frac{1}{N} X * W$$

onde '\*' representa a convolução circular em  $\mathbb{C}^N$ .

Essa proposição é uma espécie de forma inversa do teorema da convolução: aquele dizia que

*"a convolução no domínio do tempo equivale ao produto de Hadamard no domínio da frequência,"*

ao passo que a proposição 5.2.1 diz que

*"o produto de Hadamard no domínio do tempo equivale à convolução no domínio da frequência, a menos de uma constante  $\frac{1}{N}$ ."*

A demonstração desse resultado é muito parecida com a do teorema da convolução original (exercício 5.3).

### Exemplo 5.3


Considere a janela retangular  $w \in \mathbb{C}^N$ . Podemos calcular sua DFT diretamente pela definição:

$$\begin{aligned} W_k &= \sum_{n=m}^{m+M-1} e^{-i2\pi kn/N} \\ &= e^{-i2\pi km/N} \sum_{n=0}^{M-1} e^{-i2\pi kn/N} \\ &= e^{-i2\pi km/N} \frac{1 - e^{-i2\pi kM/N}}{1 - e^{-i2\pi k/N}} \end{aligned}$$

de onde (veja o exemplo idêntico na seção 2.4)



$$|W_k| = \sqrt{\frac{1 - \cos(2\pi kM/N)}{1 - \cos(2\pi k/N)}}.$$

```
In [18]: fig, axes = plt.subplots(figsize=(15,5))
axes.plot( range(-N//2, N//2), np.roll(abs(np.fft.fft(w)), N//2 ))
axes.set_title("Figura 5.3: Espectro da janela (retangular) do exemplo 5.2");
```



Essa imagem, que é o espectro da janela, explica o exemplo visto anteriormente: cada componente espectral isolada ("pico") no espectro de  $f$ , que correspondem às frequências de 96 Hz e 235 Hz, dá origem (através da convolução  $Y = \frac{1}{N} X * W$ ) a uma cópia do padrão acima. Em outras palavras, cada componente senoidal produz uma série de outras componentes secundárias *por causa* do janelamento, um fenômeno denominado **vazamento espectral**.

```
In [4]: fig, axes = plt.subplots(2,2, figsize=(15,7));axes[0,0].set_title('Espectro da
função $g_1$')
axes[0,0].plot( range(N//2) , abs(np.fft.fft(g1)[0:N//2]) );axes[0,0].axis([0,
500, 0, 300]);axes[0,1].set_title('Função $g_1$');axes[0,1].plot(g1)
axes[1,0].set_title('Espectro da função $g_2$');axes[1,0].plot( range(N//2) , a
bs(np.fft.fft(g2)[0:N//2]) )
axes[1,0].axis([0, 500, 0, 300]);axes[1,1].set_title('Função $g_2$');axes[1,1].
plot(g2);plt.show()
```



## Passo 2: "rebobinando" o sinal janelado

Para facilitar a comparação entre o espectro de

$y = w.x = (0, \dots, 0, x_m, \dots, x_{m+M-1}, 0, \dots, 0) \in \mathbb{C}^N$  e

$\tilde{x} = (x_m, \dots, x_{m+M-1}) \in \mathbb{C}^M$  consideraremos um passo intermediário, correspondente a transportar a porção janelada do sinal  $y$  para o início do vetor, através do vetor

$$\tilde{y} = (x_m, \dots, x_{m+M-1}, 0, \dots, 0) \in \mathbb{C}^N.$$

A única diferença entre  $y$  e  $\tilde{y}$  é um deslocamento para a esquerda (um "avanço" temporal) de  $m$  amostras, que afeta de forma idêntica todas as componentes do sinal, ou seja, cada componente  $Y_k E_k$  terá sua fase inicial "avançada" em  $m$  amostras, conforme estabelece a proposição a seguir.



### Proposição 5.2.2

Seja  $y \in \mathbb{C}^N$  com DFT  $Y$ . Seja  $\tilde{y} \in \mathbb{C}^N$  o sinal obtido de  $y$  por um shift circular de  $m$  amostras:

$$\tilde{y}_n = y_{n+m\%N}.$$

Então a DFT de  $\tilde{y}$  tem componentes  $\tilde{Y}_k = e^{i2\pi km/N} Y_k$ .

A demonstração dessa proposição corresponde ao exercício 2.16 (feito na lista 3).

Lembrando que no passo 1 estabelecemos que

$$Y = \frac{1}{N} X * W,$$

no final do passo 2 teremos

$$\tilde{Y}_k = e^{i2\pi km/N} \frac{1}{N} (X * W)_k.$$

### Passo 3: DFT de $N$ pontos versus DFT de $M$ pontos

Considere novamente

$\tilde{y} = (x_m, \dots, x_{m+M-1}, 0, \dots, 0) \in \mathbb{C}^N$  e  $\tilde{x} = (x_m, \dots, x_{m+M-1}) \in \mathbb{C}^M$ .  
Suas DFTs serão

$$\begin{aligned}\tilde{Y}_k &= \sum_{n=0}^{\textcolor{red}{N}-1} \tilde{y}_n e^{i2\pi kn/N} = \sum_{n=0}^{\textcolor{blue}{M}-1} \tilde{y}_n e^{i2\pi kn/\textcolor{green}{N}} \\ \tilde{X}_k &= \sum_{n=0}^{M-1} \textcolor{red}{\tilde{x}}_n e^{i2\pi kn/M} = \sum_{n=0}^{M-1} \textcolor{blue}{\tilde{y}}_n e^{i2\pi kn/\textcolor{green}{M}}.\end{aligned}$$

Note que as diferenças entre as expressões originais da DFTs e suas reformulações foram destacadas em vermelho e azul, e que as expressões finais diferem apenas nos termos em verde.

Lembrando agora que  $N = qM$  para algum  $q$  inteiro, teremos  $M = N/q$ , ou seja

$$\tilde{X}_k = \sum_{n=0}^{M-1} \tilde{y}_n e^{i2\pi kn/M} = \sum_{n=0}^{M-1} \tilde{y}_n e^{i2\pi qkn/N}.$$



Mas  $\tilde{Y}_k = \sum_{n=0}^{M-1} \tilde{y}_n e^{i2\pi kn/N}$ , de onde concluímos que

$$\tilde{X}_k = \tilde{Y}_{qk}, \quad \forall k.$$

Note que isso representa um processo de *sub-amostragem* com fator de  $q = N/M$ , e mostra que as imagens da esquerda e da direita na figura 5.2, repetida abaixo, correspondem de fato ao espectro de magnitude  $|\tilde{Y}| = |Y| \in \mathbb{C}^{1000}$  e sua versão sub-amostrada  $q = 20$  vezes  $|\tilde{X}| \in \mathbb{C}^{50}$ .

```
In [19]: w = np.zeros(N);w[99:149] = np.ones(50);ftil = w * f
fig, axes = plt.subplots(1, 2, figsize=(15,5));fig.suptitle("Figura 5.2")
axes[0].plot( range(N//2), abs(np.fft.fft(ftil)[0:N//2]) )
axes[0].axis([0, 500, 0, 14]);axes[0].set_title(r"Espectro do sinal janelado $g$
=w.\!f$")
axes[1].plot( range(25), abs(np.fft.fft(ftil[99:149])[0:25]))
axes[1].axis([0, 25, 0, 14]);axes[1].set_title(r"Espectro do sinal recortado
$\tilde{f}$");
```

Figura 5.2



Combinando os resultados dos 3 passos, chegamos ao seguinte teorema

**Teorema 5.2.1**

Seja  $x \in \mathbb{C}^N$  janelado por um sinal  $w \in \mathbb{C}^N$  onde  $w_n \neq 0 \iff m \leq n < m + M$ , e suponha que  $N = qM$ . Então a relação entre a DFT  $N$ -dimensional  $X$  de  $x$  e a DFT  $M$ -dimensional  $\tilde{X}$  de  $\tilde{x} = (w_m x_m, \dots, w_{m+M-1} x_{m+M-1}) \in \mathbb{C}^M$  é dada por

$$\tilde{X}_k = \frac{e^{i2\pi m q k / N}}{N} (X * W)_{qk} = \frac{e^{i2\pi m k / M}}{N} (X * W)_{qk},$$





onde a última igualdade segue de  $q/N = 1/M$ .

## Exemplo 5.4

O teorema 5.2.1 mostra que o janelamento e subsequente recorte promove alterações no conteúdo espectral do recorte analisado que têm relação direta com a janela utilizada.

Podemos investigar o efeito da escolha da janela considerando a DFT  $W$  para diferentes tamanhos de  $M$ , conforme ilustrado abaixo.


```
In [5]: M = np.array([3, 10, 100, 250]); fig, axes = plt.subplots(2, 2, figsize=(15,7))
for j in range(2):
    for i in range(2):
        index = 2 * i + j; w = np.concatenate((np.ones(M[index]), np.zeros(N-M[
index])))
        axes[i, j].plot(range(-N // 2, N // 2), np.roll(abs(np.fft.fft(w)), N
// 2)); axes[i, j].set_xlim([-N / 2 + 1, N / 2])
        axes[i, j].set_title("Espectro da janela retangular com M={}".format(M[i
ndex]))
```







```
In [6]: M = np.array([3, 10]);fig, axes = plt.subplots(len(M), 2, figsize=(15,7));fig.s
uptitle("Exemplo adicional: Figura 5.2 com diferentes tamanhos de janela")
for j in range(len(M)):
    w = np.concatenate( (np.ones(M[j]), np.zeros(N-M[j])) );ftil = w * f;fcut =
ftil[0:M[j]]
    axes[j,0].plot(range(N//2+1), abs(np.fft.fft(ftil)[0:N//2+1]));axes[j,0].se
t_xlim([0, N//2]);axes[j,0].set_title("Espectro do sinal janelado com M={}".form
at(M[j]))
    axes[j,1].plot(range(M[j]//2+1), abs(np.fft.fft(fcut)[0:M[j]//2+1]));axes[j
,1].set_xlim([0, M[j]//2]);axes[j,1].set_title("Espectro do sinal recortado com
M={}".format(M[j]))
```

Exemplo adicional: Figura 5.2 com diferentes tamanhos de janela



```
In [7]: M = np.array([100, 250]);fig, axes = plt.subplots(len(M), 2, figsize=(15,7));fig.suptitle("Exemplo adicional: Figura 5.2 com diferentes tamanhos de janela")
for j in range(len(M)):
    w = np.concatenate( (np.ones(M[j]), np.zeros(N-M[j])) );ftil = w * f;fcut =
ftil[0:M[j]]
    axes[j,0].plot(range(N//2+1), abs(np.fft.fft(ftil)[0:N//2+1]));axes[j,0].set_xlim([0, N//2]);axes[j,0].set_title("Espectro do sinal janelado com M={}".format(M[j]))
    axes[j,1].plot(range(M[j]//2+1), abs(np.fft.fft(fcut)[0:M[j]//2+1]));axes[j,1].set_xlim([0, M[j]//2]);axes[j,1].set_title("Espectro do sinal recortado com M={}".format(M[j]))
```

Exemplo adicional: Figura 5.2 com diferentes tamanhos de janela



### Seção 5.2.3: Espectrogramas

Uma forma de analisar um sinal com conteúdo variável no domínio da frequência corresponde a segmentar o sinal, escolhendo um tamanho de janela  $M$  que seja pequeno o suficiente para que o conteúdo do sinal seja relativamente estável no intervalo de tempo correspondente a uma janela, e computar uma DFT para cada janela, produzindo uma **Transformada de Fourier de Tempo Reduzido (STFT)** ou **Espectrograma**.

Em relação aos inícios das janelas, podemos ter o  $k$ -ésimo segmento começando na posição  $m = kn$ , ou seja,

$$\tilde{x}^k = (x_{kn}, x_{kn+1}, \dots, x_{kn+M-1}).$$

Dependendo do parâmetro  $n$ =distância entre inícios de segmentos sucessivos, podemos ter:

- se  $n = M$ , teremos  $\tilde{x}^0 = (x_0, x_1, \dots, x_{M-1})$ ,  $\tilde{x}^1 = (x_M, x_{M+1}, \dots, x_{2M-1})$ , etc. Nesse caso as janelas são *justapostas*;
- se  $n < M$ , teremos  $\tilde{x}^0 = (x_0, x_1, \dots, x_{M-1})$  e  $\tilde{x}^1 = (x_n, x_{n+1}, \dots, x_{n+M-1})$ , onde algumas amostras aparecem nos segmentos sucessivos. Nesse caso as janelas são *sobrepostas*;





Frequentemente a sobreposição é definida através de um *fator de sobreposição*: janelas com sobreposição de 50% por exemplo correspondem a  $n = M/2$ , e em geral definir  $n = \alpha M$  com  $\alpha \in (0, 1)$  acarretará uma sobreposição de  $100(1 - \alpha)\%$ .

- o caso  $n > M$  não é usado com tanta frequência, pois nesse caso as janelas não cobrem todo o sinal, deixando porções temporais fora da análise.

## Exemplo 5.5

Considere outra vez o sinal do exemplo 5.1:  $g(t) = \begin{cases} \sin(2\pi(96)t), & 0 \leq t < \frac{1}{2} \\ \sin(2\pi(235)t), & \frac{1}{2} \leq t \leq 1. \end{cases}$

```
In [56]: N = 1000; t = np.arange(0, 1, 1/N); f = 0.5*np.sin(2*m.pi*96*t)+0.5*np.sin(2*m.pi
*235*t)
g = np.concatenate( (np.sin(2*m.pi*96*t[0:N//2])), np.sin(2*m.pi*235*t[N//2:N]))
, axis=0)
M = np.array([20, 50, 100, 200]); o = 0.6 * M # saltos de 60% do valor da janela
o[3] = 10; show_spectra(N, t, g, M, o)
```



## Exemplo 5.6


Nesse exemplo consideramos um sinal com 3 componentes senoidais, sendo uma com frequência instantânea variável:

$$f(t) = 1.0 \sin(2\pi(111)t) + 0.5 \sin(2\pi(123)t) + 0.5 \sin(2\pi\omega(t)t),$$

onde  $\omega(t) = 150 + 50 \cos(2\pi t)$ , para  $t \in [0, 1)$  com taxa de amostragem  $R = 1000$  Hz.





Vamos visualizar o espectro do sinal inteiro, e algumas versões de espectrogramas com diferentes escolhas de  $M$  e  $n$ .

```
In [9]: N = 1000; t = np.linspace(0, 1-1/N, N); omega = 150 + 50 * np.cos(2*m.pi * t)
f = np.sin(2*m.pi* 111 * t)+0.5*np.sin(2*m.pi* 123 * t)+0.5*np.sin(2*m.pi* omega
a * t)
plt.figure(figsize=(15,5)); plt.plot(range(N//2), np.log(1+abs(np.fft.fft(f)[1:N
//2+1])))
plt.xlim([0, N/2]); plt.title("Espectro do sinal com 2 senoides fixas e 1 com fre
quencia variavel");
```





```
In [60]: M = np.array([500, 100, 50, 20]); f0 = np.array([100, 20, 10, 4]); show_spectra(N,  
t, f, M, f0)
```



## Exemplo 5.6: frequência instantânea

Os espectrogramas acima deixam claro que a frequência instantânea da 3a componente

$$f_3(t) = 0.5 \sin(2\pi\omega(t)t)$$

não é a própria função  $\omega(t) = 150 + 50 \cos(2\pi t)$ , que varia apenas entre 100 e 200, mas sim a variação instantânea da fase (argumento do seno), cuja expressão é


$$\tilde{\omega}(t) = \frac{\partial 2\pi\omega(t)t}{\partial t} = 2\pi (\omega(t) + \omega'(t)t) = 2\pi (150 + 50 \cos(2\pi t) - 100\pi \sin(2\pi t)t),$$

em radianos/segundo, ou equivalentemente em Hz

$$\tilde{f}(t) = 150 + 50 \cos(2\pi t) - 100\pi \sin(2\pi t)t,$$

cujas faixa de variação *aumenta* com  $t$ , como pode ser evidenciado pelo gráfico abaixo (compare-o com os últimos espectrogramas).



```
In [16]: omegatil = omega - 100*m.pi*np.sin(2*m.pi * t)*t  
plt.plot(t,omegatil);plt.axis([0, 1, 0, 500]);  
plt.title(r"frequência instantânea  $\tilde{f}(t)$ ");plt.show()
```



## Seção 5.2.4: Outros tipos de janela

Até esse momento só vimos exemplos usando a janela retangular ( $w_n = 1$  se  $m \leq n < m + M$ ,  $w_n = 0$  caso contrário). Porém o resultado do teorema 5.2.1 vale para outras formas de janela, que podem ter impactos diferentes sobre o espectro dos recortes do sinal.

```
In [61]: N = 1000; wr = np.zeros(N); wr[99:149] = np.ones(50)
fig, axes = plt.subplots(1,2, figsize=(15,5))
axes[0].set_title('Janela retangular'); axes[0].plot(range(-2, 52), wr[97:151])
freqs = np.linspace(-N/2, N/2, N); Fmag = abs(np.fft.fft(wr))
axes[1].set_title('Espectro da janela retangular'); axes[1].plot(freqs, np.fft.ff
tshift(Fmag));
```





## Janela triangular ('Bartlett')

Definida por

$$w_j = \begin{cases} \frac{2j}{M}, & m \leq j \leq m + M/2, \\ \frac{M+m-1-j}{M/2+m-1}, & m + M/2 < j < m + M, \\ 0, & \text{c.c.} \end{cases}$$

```
In [63]: win = np.bartlett(50)  
plot_window_func(win, N, 'Bartlett')
```



## Janela Gaussiana



Definida por

$$w_j = Ce^{-\alpha \left( \frac{j-(m+(M-1)/2)}{M/2} \right)^2}$$

onde  $C$  e  $\alpha$  são parâmetros definidos pelo usuário.



```
In [67]: sigma = 10  
win = signal.gaussian(50, sigma)  
plot_window_func(win, N, 'Gaussiana')
```





## Janela de Hamming

Definida por

$$w_j = \begin{cases} 0.54 - 0.46 \cos\left(2\pi \frac{j-m}{M}\right), & m \leq j \leq m + M, \\ 0, & \text{c.c.} \end{cases}$$

```
In [68]: win = np.hamming(50)  
plot_window_func(win, N, 'Hamming')
```



```
In [70]: fig, axes = plt.subplots(1,2, figsize=(15,5))
axes[0].plot(ns, win_bartlett, 'g-', label='Bartlett')
axes[0].plot(ns, win_hamming, 'r-', label='Hamming')
axes[0].plot(ns, win_gaussian, 'b-', label='Gaussiana')
axes[1].plot(freqs, np.fft.fftshift(spec_bartlett), 'g-', label='Bartlett')
axes[1].plot(freqs, np.fft.fftshift(spec_hamming), 'r-', label='Hamming')
axes[1].plot(freqs, np.fft.fftshift(spec_gaussian), 'b-', label='Gaussiana')
plt.legend(loc='upper left', bbox_to_anchor=(1, 1));plt.show()
```

