
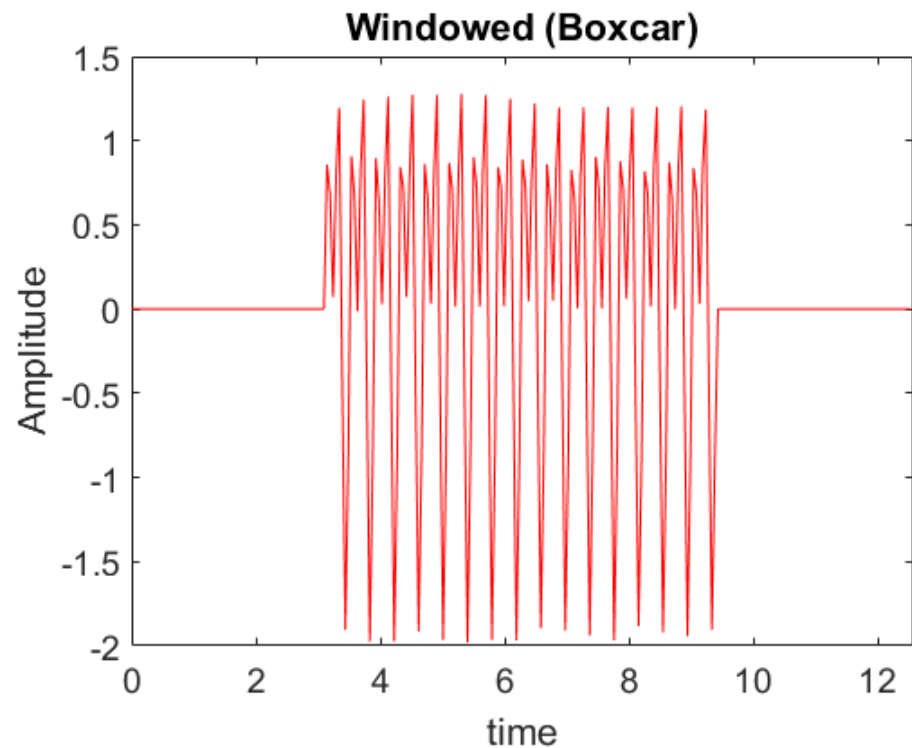


# Introdução a análise temporal-espectral

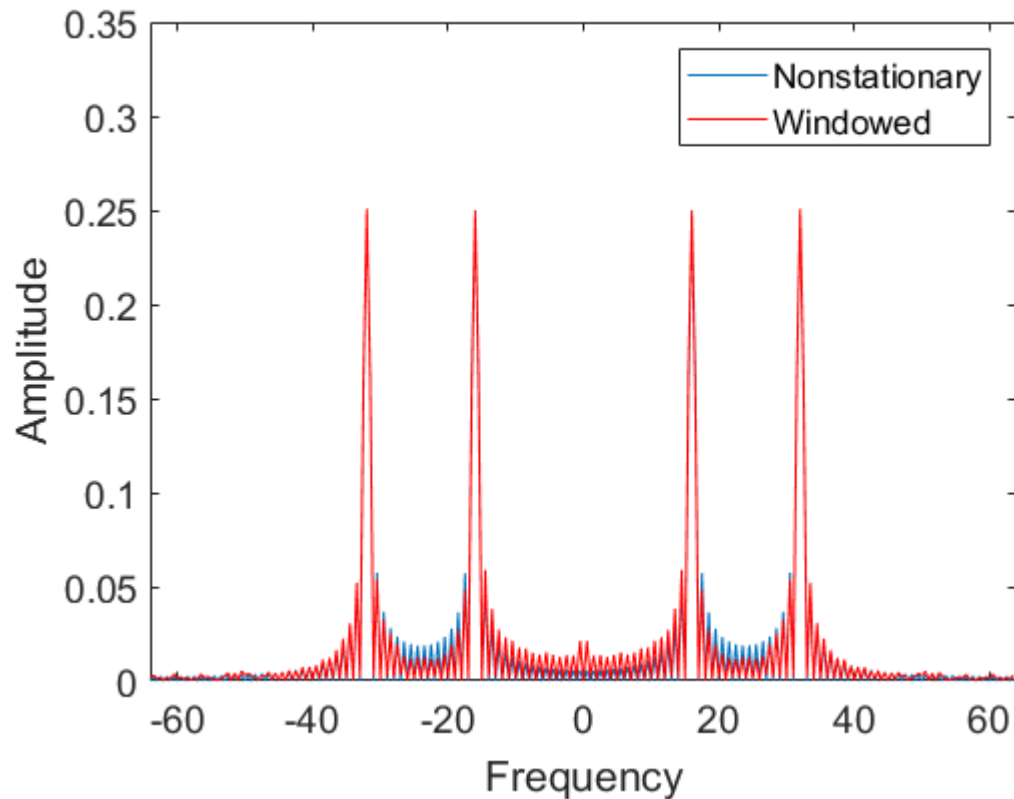
# Introdução

- As ferramentas vistas até o momento, são muito poderosas na análise espectral de sinais estacionários.
- No caso de sinais não estacionários, é possível aplicar o que já foi visto? Discutir



# Introdução


- Espectro dos dois sinais do slide anterior (muito parecidos).



- Nota-se que a representação espectral diz muito pouco sobre eventos localizados no tempo ou espaço.



# Motivação

- Alguns processos físicos exibem características não estacionárias, como por exemplo, sinais sonoros de fala e música



# Motivação

- O espectro do áudio pode ser visualizado abaixo



# Motivação

- Nota-se que é difícil extrair alguma informação relevante, de um sinal não estacionário, usando as ferramentas que foram vistas até a presente aula.
- Como podemos adaptar o que foi visto para a análise deste tipo de sinal?

obs: considerando que o sinal não estacionário, é aproximadamente estacionário durante um intervalo curto de tempo

# Introdução

- A solução para esse problema pode ser obtida com transformada de Fourier de tempo curto
- A ideia é aplicar a transformada de Fourier em intervalos curtos de tempo. Durante esse intervalo, assume-se que as propriedades estatísticas do sinal não possuem grande variação.
- A redução do tamanho de um vetor de amostras já foi utilizada anteriormente para o cálculo da Densidade Espectral de Potência e da Bicoerência.
- Naqueles casos, o aumento do número de blocos foi utilizado para se aumentar a confiabilidade da estimativa da PSD e da bicoerência.



# Introdução

- No caso da transformada de Fourier de Tempo curto, cada sub-amostra é relacionada ao instante de amostragem dos dados.
- Assim, pode-se utilizar a transformada de Fourier para a representação espectral de cada bloco
- A variação do conteúdo espectral de cada bloco pode ser visualizada ao longo do tempo, criando-se assim uma representação no temporal e espectral.
- Por isso a ferramenta é empregada na análise tempo x frequência



# Introdução

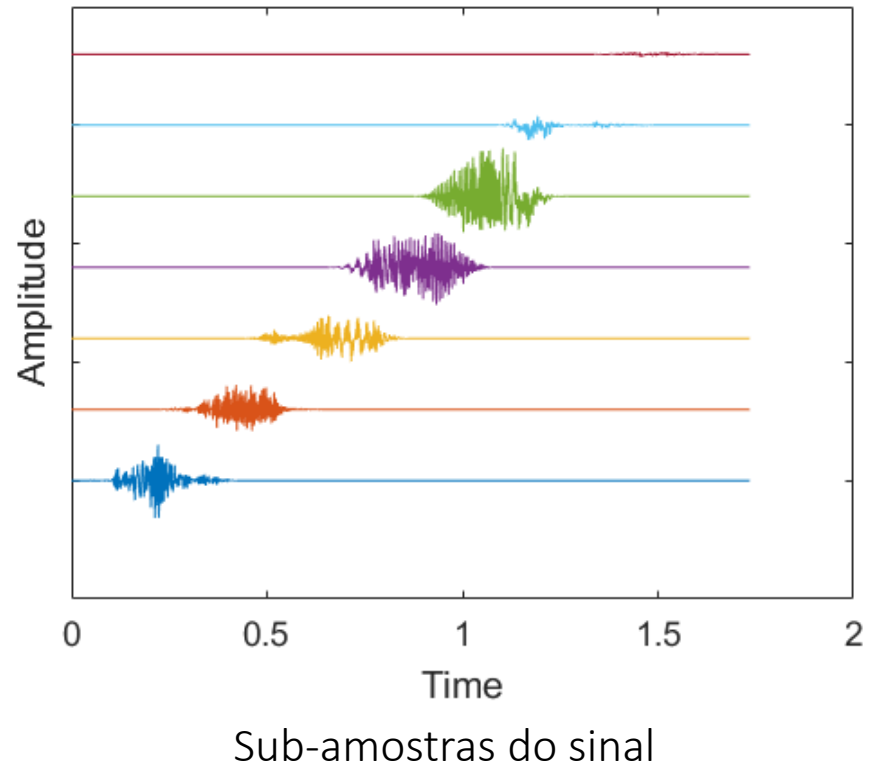

- O procedimento pode ser ilustrado na sequência a seguir



Janelas deslocadas no tempo

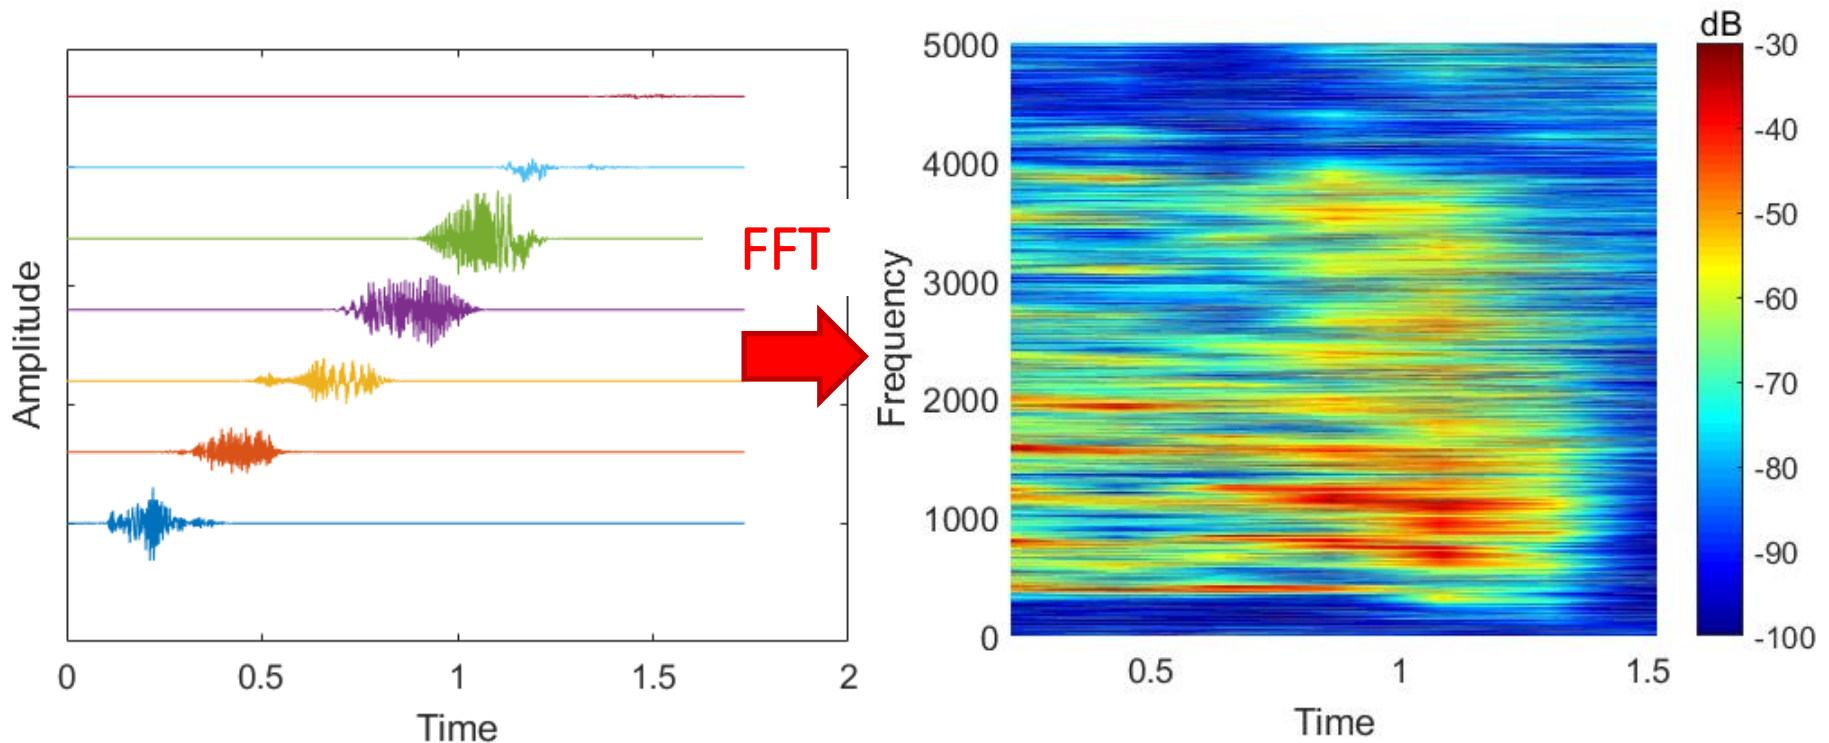
# Introdução

- O procedimento pode ser ilustrado na sequência a seguir



# Introdução

- O procedimento pode ser ilustrado na sequência a seguir



Espectrograma do sinal

# Enjanelamento

- Para retirar uma sub-amostra do sinal, definimos uma função de enjanelamento  $w[n, \tau]$ , tal que:

$$w[n, \tau] \rightarrow w[(n - \tau)]$$

- A função de enjanelamento pode ser qualquer uma daquelas já discutidas, a diferença é que para a análise tempo – frequência elas são deslocadas de  $\tau$  para a sub-amostragem do sinal
- As funções de enjanelamento mais comuns são as janelas Hanning, Hamming e Gaussiana
- No caso dessa última, a transformada é conhecida como transformada de Gabor em homenagem a Denis Gabor (1900-1979)

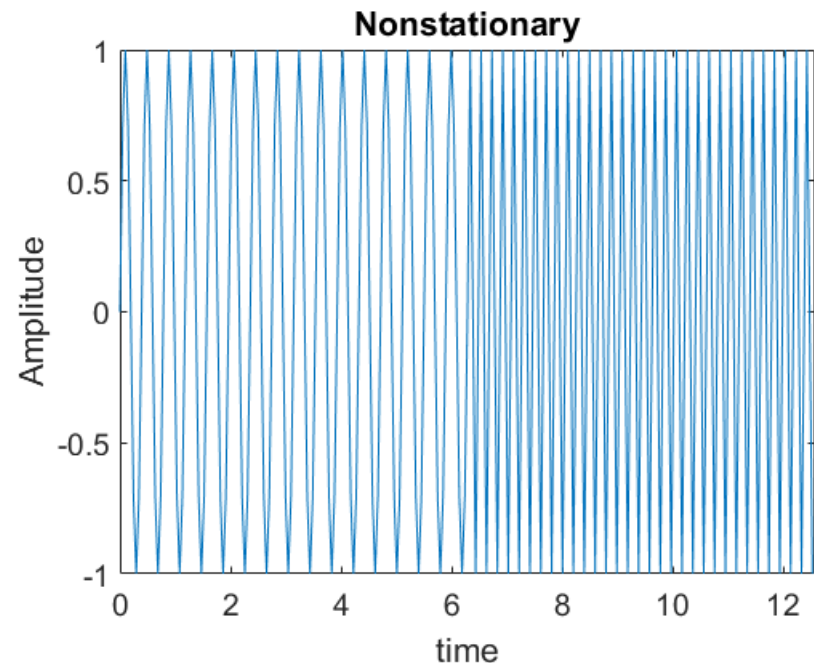
# Transformada de Fourier de tempo curto

- A transformada de Fourier de tempo curto (Short Time Fourier Transform-STFT), na forma discreta, pode ser definida como:

$$X(m, k) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]w[n-m]e^{-i\omega_0kn}$$

Onde o produto  $x[n]w[n-m]$  é uma sub-amostra do sinal  $x[n]$


- **Exemplo de aplicação**  
Voltando ao sinal do início da aula



# Transformada de Fourier de tempo curto

## ➤ Exemplo de aplicação.


Sub-amostras com função de enjanelamento do tipo Hanning



# Transformada de Fourier de tempo curto

## ➤ Exemplo de aplicação.


Aplicando FFT a cada sub-amostra



# Transformada de Fourier de tempo curto

## ➤ Exemplo de aplicação.

Apresentando-se em mapa de cores, o espectrograma fica



Para sinais reais, normalmente, só se apresenta a parte do espectro relacionada com as frequências positivas

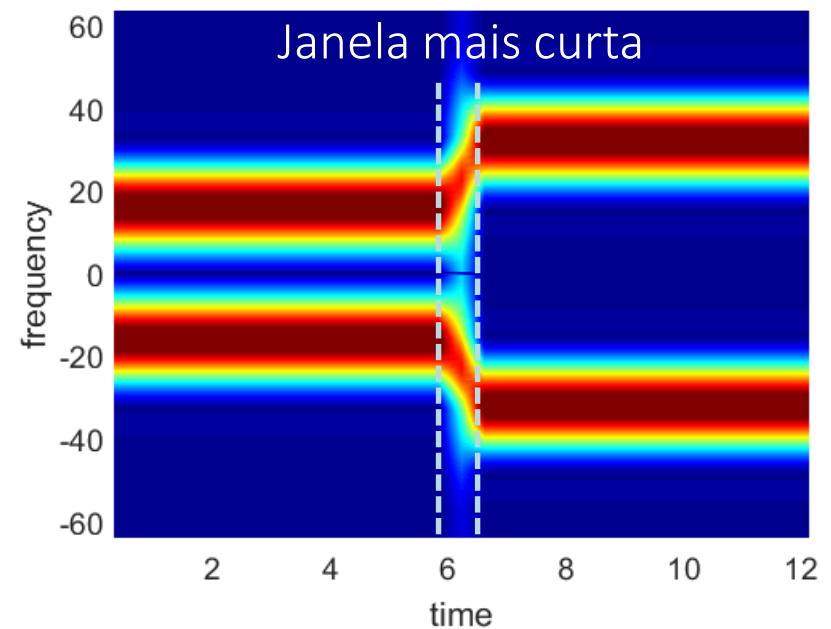
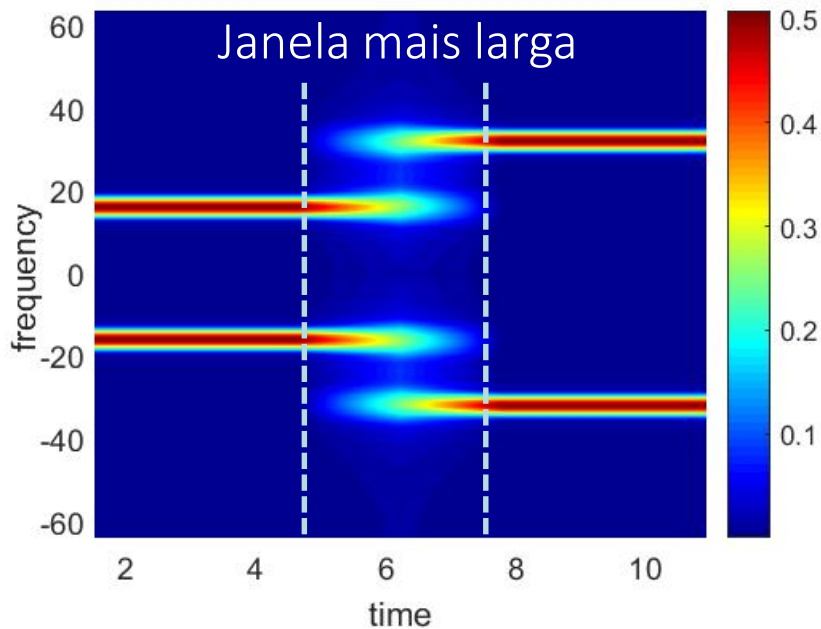


# Resolução

- Pode-se notar que a quantidade de espectros estimados depende do número de sub-amostras.
- Para se aumentar o número de sub-amostras, pode-se reduzir o tamanho de cada sub-amostra
- Qual a implicação disso?

# Resolução

- Reduzindo-se o tamanho das sub-amostras, ou o período de enjanelamento, a resolução em frequência do espectrograma se torna mais grosseira.
- Em contrapartida a resolução temporal melhora. Já com o aumentando no tamanho da janela, o efeito é o contrário.



# Resolução

- Desenho esquemático da resolução temporal e espectral
- É interessante observar também que a discretização no tempo e na frequência são constantes para um dado tamanho de janela



# Resolução

- De acordo com Heisenberg (incerteza), existe uma incerteza associada com a resolução temporal e espacial.

$$\Delta t \Delta f \geq \frac{1}{4\pi}$$

- A relação de Heisenberg, mostra que não é possível obter simultaneamente uma alta resolução temporal e espacial

# Transformação inversa

- Não é muito claro se o sinal original pode ser recuperado a partir do espectrograma.
- De acordo com a definição da STFT na forma discreta

$$X(m, k) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]w[n-m]e^{-i\omega_0kn}$$

- O tamanho, o espaçamento e o tipo de função de enjanelamento influenciam na representação espectral do sinal
- Em algumas situações a soma da sobreposição das janelas em um instante de tempo é constante e igual a 1.

$$\sum_{m=0}^{M-1} w[n-m] = 1, \quad \forall n \text{ Inteiro}$$

# Transformação inversa

- Nesse caso a soma das sucessivas FFTs ficam:

$$\begin{aligned}\sum_{m=0}^{M-1} X(m, k) &= \frac{1}{N} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} x[n] w[n-m] e^{-i\omega_0 kn} \\ &= \frac{1}{N} \sum_{n=0}^{N-1} x[n] e^{-i\omega_0 kn} \underbrace{\sum_{m=0}^{M-1} w[n-m]}_1\end{aligned}$$

$$X[k] = \frac{1}{N} \sum_{n=0}^{N-1} x[n] e^{-i\omega_0 kn}$$

- Logo, fica claro que a soma das transformadas equivale a transformada de  $x[n]$ , se a soma das janelas sobrepostas for constante e igual a 1



# Transformação inversa

- Isso implica na existência da transformação inversa.
- Para a soma das transformadas ser realmente equivalente a transformada do sinal, é necessário que a informação nos instantes iniciais e finais da série de dados seja considerada. Para isso deve-se assumir o sinal como sendo periódico. Outra possibilidade (não tão boa) é preencher meia janela no início e no final com zeros.
- Dentre as diversas funções de enjanelamento, a janela retangular sem sobreposição satisfaz a condição.
- A janela de Barlett e todas as janelas da família Hanning e Hamming também satisfazem essa condição para uma sobreposição de 50%.

# Exemplos e Aplicações

## ➤ Sinal Chirp

```
t_chirp=0:2/2048:2-2/2048;  
ychirp=chirp(t_chirp,0,2,50);
```






# Exemplos e Aplicações

➤ Análise de voz (`speech_processing.m`)

Em sala

# Exemplos e Aplicações

➤ Análise de musica



# Exercícios

- Exercício 1) Criar um sinal do tipo chirp, partindo de  $t=0$  até 5 segundos com frequência final de 100Hz. Apresentar o espectrograma desse sinal
- Exercício 2) Fazer um espectrograma médio (pelo menos 5 amostras) de uma pessoa dizendo palavra “*processamento*”.

Dica 1) No slide seguinte é fornecida uma função para gravação de áudio utilizando o microfone do computador. Caso não possua um microfone, é possível fazer a gravação utilizando um fone de ouvido ligado a entrada de áudio do computador.

Dica 2) Para a extração do espectrograma médio, será necessário fazer uma amostragem condicional do sinal.

# Exercícios

```
function [y,fs] = read_mic
% Function to record a signal from computer microphone
recObj = audiorecorder;
disp('Press enter and start speaking.')
pause
recordblocking(recObj, 4); % recording 4 seconds
disp('End of Recording. ');
%
%% signal acquisition
play(recObj);
y = getaudiodata(recObj);
info = audiodevinfo;
fs=recObj.SampleRate;
%%play the signal
sound(y,fs);
end
```