

Introdução a transformada wavelet

Texto complementar à literatura do curso:
M. Farge, 1992, “*Wavelet transforms and their applications to turbulence*”. Ann. Rev. Fluid Mech


Revisão da análise no domínio da frequência

- Podemos resumir, esquematicamente, o que já foi visto sobre análise temporal e espectral nos seguintes diagramas

Representação no domínio do tempo

Tempo


Frequência



Representação no domínio da frequência - Fourier

Tempo

Frequência



Revisão da análise no domínio da frequência

- Na aula passada vimos que outra representação é possível

Representação tempo-frequência


STFT




Tempo

Tempo

Frequência



Frequência



Revisão da análise no domínio da frequência

- Na representação tempo frequência, define-se um intervalo de tempo para a análise e obtém-se uma faixa de frequências correspondente. (Devido a incerteza de Heisenberg não é possível obter alta resolução tanto no tempo como frequência)

Representação tempo-frequência

STFT (*Short Time Fourier Transform*)

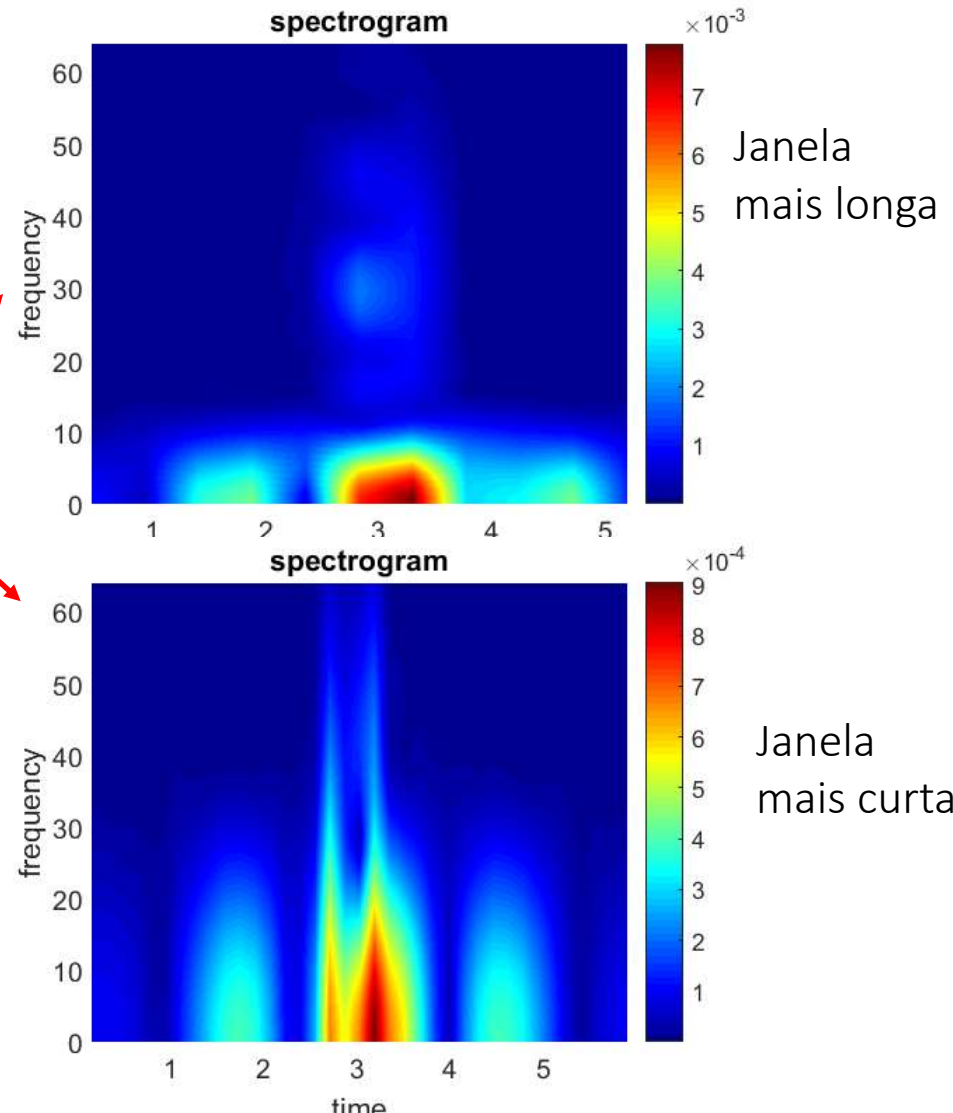

Tempo

| | | | | |
|--|--|--|--|--|
| | | | | |
| | | | | |
| | | | | |
| | | | | |
| | | | | |

O que fazer quando se deseja analisar variação localizadas no tempo, sem desprezar frequências baixas (tempos longos)?

Motivação

- Exemplo. Sinal com oscilação de baixa frequência com eventos localizados no tempo.



Introdução a Transformada Wavelet

- A transformada Wavelet busca suprir essa limitação da transformada de tempo curto.
- Na transformada Wavelet, busca-se resolver com uma alta resolução espectral (consequentemente baixa resolução temporal) as oscilações de baixa frequência. Já as oscilações de mais alta frequência são resolvidas com alta resolução temporal e baixa resolução espectral.
- Essa variação de resolução se assemelha, por exemplo, a sensibilidade auditiva humana.
- Se pegarmos a escala musical, vemos que a cada oitava a frequência dobra. Assim, o espaçamento espectral entre as notas se torna maior e precisamos de menor resolução no espectro para resolver essas notas.


Introdução a Transformada Wavelet

Note Frequency Chart

| | Octave 0 | Octave 1 | Octave 2 | Octave 3 | Octave 4 | Octave 5 | Octave 6 | Octave 7 | Octave 8 |
|----|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| C | 16.35 | 32.70 | 65.41 | 130.81 | 261.63 | 523.25 | 1046.50 | 2093.00 | 4186.01 |
| C# | 17.32 | 34.65 | 69.30 | 138.59 | 277.18 | 554.37 | 1108.73 | 2217.46 | 4434.92 |
| D | 18.35 | 36.71 | 73.42 | 146.83 | 293.66 | 587.33 | 1174.66 | 2349.32 | 4698.64 |
| D# | 19.45 | 38.89 | 77.78 | 155.56 | 311.13 | 622.25 | 1244.51 | 2489.02 | 4978.03 |
| E | 20.60 | 41.20 | 82.41 | 164.81 | 329.63 | 659.26 | 1318.51 | 2637.02 | 5274.04 |
| F | 21.83 | 43.65 | 87.31 | 174.61 | 349.23 | 698.46 | 1396.91 | 2793.83 | 5587.65 |
| F# | 23.12 | 46.25 | 92.50 | 185.00 | 369.99 | 739.99 | 1479.98 | 2959.96 | 5919.91 |
| G | 24.50 | 49.00 | 98.00 | 196.00 | 392.00 | 783.99 | 1567.98 | 3135.96 | 6271.93 |
| G# | 25.96 | 51.91 | 103.83 | 207.65 | 415.30 | 830.61 | 1661.22 | 3322.44 | 6644.88 |
| A | 27.50 | 55.00 | 110.00 | 220.00 | 440.00 | 880.00 | 1760.00 | 3520.00 | 7040.00 |
| A# | 29.14 | 58.27 | 116.54 | 233.08 | 466.16 | 932.33 | 1864.66 | 3729.31 | 7458.62 |
| B | 30.87 | 61.74 | 123.47 | 246.94 | 493.88 | 987.77 | 1975.53 | 3951.07 | 7902.13 |

Introdução a Transformada Wavelet


- Seguindo essa analogia, na transformação Wavelet o espectro é resolvido da seguinte maneira:



Como fazer isso?

Introdução a Transformada Wavelet


- Consideremos um sinal qualquer



- Já vimos da STFT que a variação do espectro no tempo é feita em sub-amostras da série de dados. Para variar a resolução temporal é necessário variar o comprimento da série de dados.

Introdução a Transformada Wavelet

- Vimos também que, para separar as amostras e evitar descontinuidades, podemos usar funções de enjanelamento.




- Na seleção das janelas na STFT, não foi dada grande importância ao conteúdo espectral da função de enjanelamento.
- Se quisermos uma janela finita e localizada tanto no tempo como na frequência, temos que buscar funções especiais (wavelets)


Introdução a Transformada Wavelet

- Na análise de filtros e janelas, vimos que algumas funções de enjanelamento espalham oscilações em todo o espectro e que alguns filtros espalham oscilações em toda a série temporal.


Ex.: Janela retangular



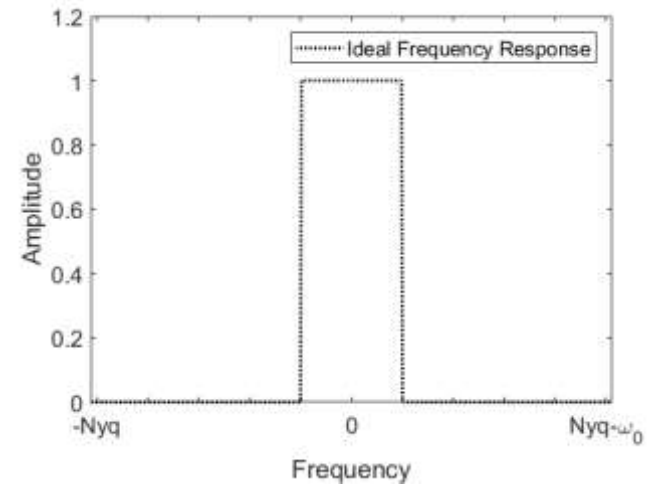
FFT



Ex.: Filtro ideal





IFFT



Introdução a Transformada Wavelet

- Logo, uma análise tempo-frequência, com resolução variável, requer funções características que permitam, ao mesmo tempo, isolar uma faixa de frequências e um intervalo com duração finita.



- As funções que tem essa característica e satisfazem algumas outras restrições são chamadas de wavelets

Introdução a Transformada Wavelet

- As funções escolhidas como wavelets devem permitir:
 - deslocamento no tempo (para varredura ao longo da série de dados);
 - dilatação e compressão (para variação da largura da janela);
 - deslocamento no espectro (para varredura do conteúdo espectral do sinal – filtro passa banda ajustável)
- A largura da janela e a faixa de frequências capturadas são relacionadas e podem ser descritas por um único parâmetro da função wavelet (“ s ”)

Introdução a Transformada Wavelet

- Assim, uma função wavelet no tempo ($\psi_{s,\tau}(t)$) pode ser escrita, de maneira geral como:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi \left[\frac{t - \tau}{s} \right] \quad \text{Wavelet Mãe}$$

- Nota-se que o parâmetro “s” sugere uma dilatação ou compressão da escala de tempo da função Ψ
- O fator \sqrt{s} é uma normalização para que independentemente da dilatação todas as ondas tenham a mesma energia.
- O parâmetro τ é um deslocamento da função no tempo
- No domínio da frequência a função geral fica:

$$\Psi_{s,\tau}(\omega) = \sqrt{s} e^{-i\tau\omega} \Psi[s\omega]$$

Introdução a Transformada Wavelet

- Algumas janelas podem causar espalhamento em todo o espectro, dependendo da dilatação.
- Além disso, as funções wavelets devem ter médias iguais a zero, para não adicionar nenhuma tendência a transformação.
- Dessas duas restrições, tem-se as condições de admissibilidade das wavelets (para qualquer s e τ):

$$C_{\psi} = \int \frac{|\Psi(\omega)|}{|\omega|} d\omega < \infty$$

$$\int \psi(t) dt = 0$$

Transformada Wavelet

- A partir da admissibilidade da função wavelet, podemos utilizá-la como uma base de referência e fazer a transformação do sinal (Fourier utilizou senos e cossenos, aqui utiliza-se uma função wavelet).
- Define-se a Transformada Wavelet Contínua (CWT, *Continuous Wavelet Transform*) como sendo a convolução entre a função $x(t)$ e a função wavelet $\psi_{s,\tau}(t)$ para uma escala s .

$$W_{s,\tau} = \frac{1}{\sqrt{s}} \int x(t) \psi^* \left[\frac{t - \tau}{s} \right] dt = \int x(t) \psi_{s,\tau}^* (t) dt$$

Onde $W_{s,\tau}$ é a transformada wavelet da função $x(t)$ no tempo t , para uma escala s . * denota o conjugado complexo.

Transformada Wavelet

- Respeitando-se as condições de admissibilidade é possível recuperar o sinal original a partir dos coeficientes da transformada $W_{s,\tau}$ (transformação inversa, ICWT)

$$x(t) = \frac{1}{C_\psi} \int \int W_{s,\tau} \psi_{s,\tau}(t) \frac{dsd\tau}{s^2}$$

- Na transformação wavelet a energia se conserva, e uma extensão da relação Parseval é observada (wavelets ortogonais)

$$\int |x(t)|^2 dt = \frac{1}{C_\psi} \int \int |W_{s,\tau}|^2 \frac{dsd\tau}{s^2}$$

- A energia em cada escala fica

$$E(s) = \frac{1}{C_\psi} \int |W_{s,\tau}|^2 \frac{d\tau}{s^2}$$

Transformada Wavelet

- Sabemos que a convolução pode ser eficientemente implementada no domínio de Fourier. Assim, CWT pode ser obtida via IFT da convolução no domínio da frequência.

$$W_{s,\tau} = \frac{1}{2\pi} \int X(\omega) \Psi_{s,\tau}^*(\omega) d\omega$$

- No caso de sinais discretos a CWT, pode ser escrita como:

$$W_s[\tau] = \frac{1}{N} \sum_{k=0}^{N-1} X[k] \Psi_s^*[k] e^{i\omega_0 k \tau}, \quad \text{para } \tau = 0, 1, 2 \dots N - 1$$

Onde: $X[k] = \mathcal{F}\{x[n]\}$ e $\Psi_s[k] = \mathcal{F}\{\psi_s[n]\}$, e $\omega_0 = 2\pi/N$

Escalas de tempo e frequência

- Localização no tempo é uma medida de concentração de $\psi_{s,\tau}$ em torno de um tempo (faz sentido para wavelets assimétricas):

$$\mu_\tau = \frac{1}{\|\psi_{s,\tau}\|^2} \int t |\psi_{s,\tau}(t)|^2 dt$$

- Já a frequência central de cada escala é dada de maneira análoga por:

$$\mu_\omega = \frac{1}{\|\Psi_s\|^2} \int \omega |\Psi_s(\omega)|^2 d\omega$$

Para algumas funções wavelets a relação entre escala de dilatação e deslocamento no tempo podem ser obtidas analiticamente.

Como funciona a transformação

- Primeiro vamos definir uma função wavelet.
- Nesse exemplo, usaremos uma muito comum, conhecida como Morlet (Morlet et. al. 1983).
- Essa função corresponde ao produto entre uma senoide complexa e uma gaussiana na forma:


$$\psi_{s,\tau}(t) \sim e^{-2\pi i f_c(t-\tau)} e^{-\frac{(t-\tau)^2}{2s^2}}$$

Senóide Gaussiana

Onde s é o fator de dilatação da escala de tempo da gaussiana e f_c a frequência central da senoide.

Como funciona a transformação

- Função wavelet no tempo e no domínio da frequência ($\tau=0.5$, $f_c=20$ e $s=0.04$)



Como funciona a transformação

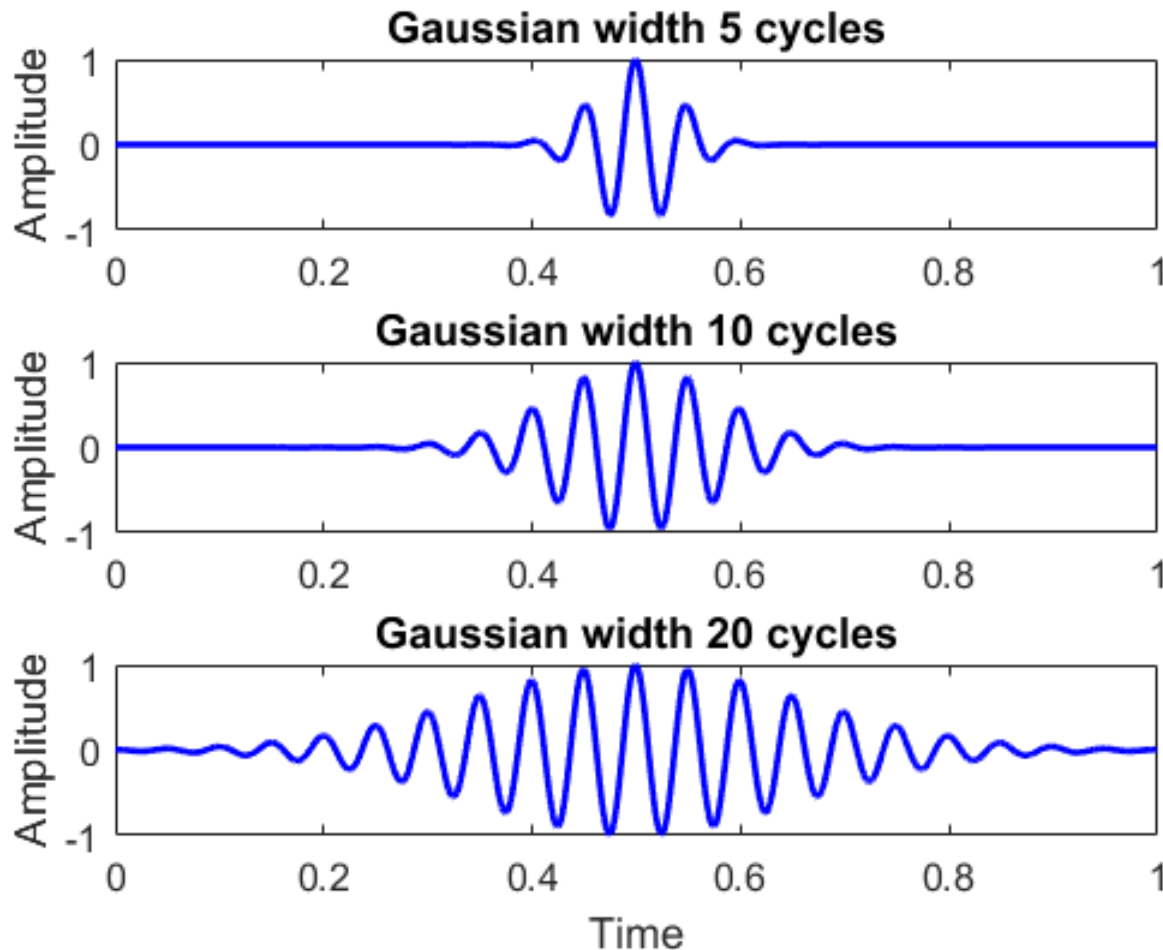
- Para manter a relação das ondas com a wavelet mãe, é necessário que o número de ciclos por janela (“ nc ”) não se modifique, mesmo que a frequência da senóide (f_c) mude
- Logo, existe uma relação entre f_c e s para um número constante de ciclos (nc) por janela. Para a função janela do exemplo, essa relação é dada por

$$s = \frac{nc}{2\pi f_c}$$

- A relação número de ciclos por janela, para uma dada frequência têm influência na largura da janela e conseqüentemente no espalhamento da função no espectro

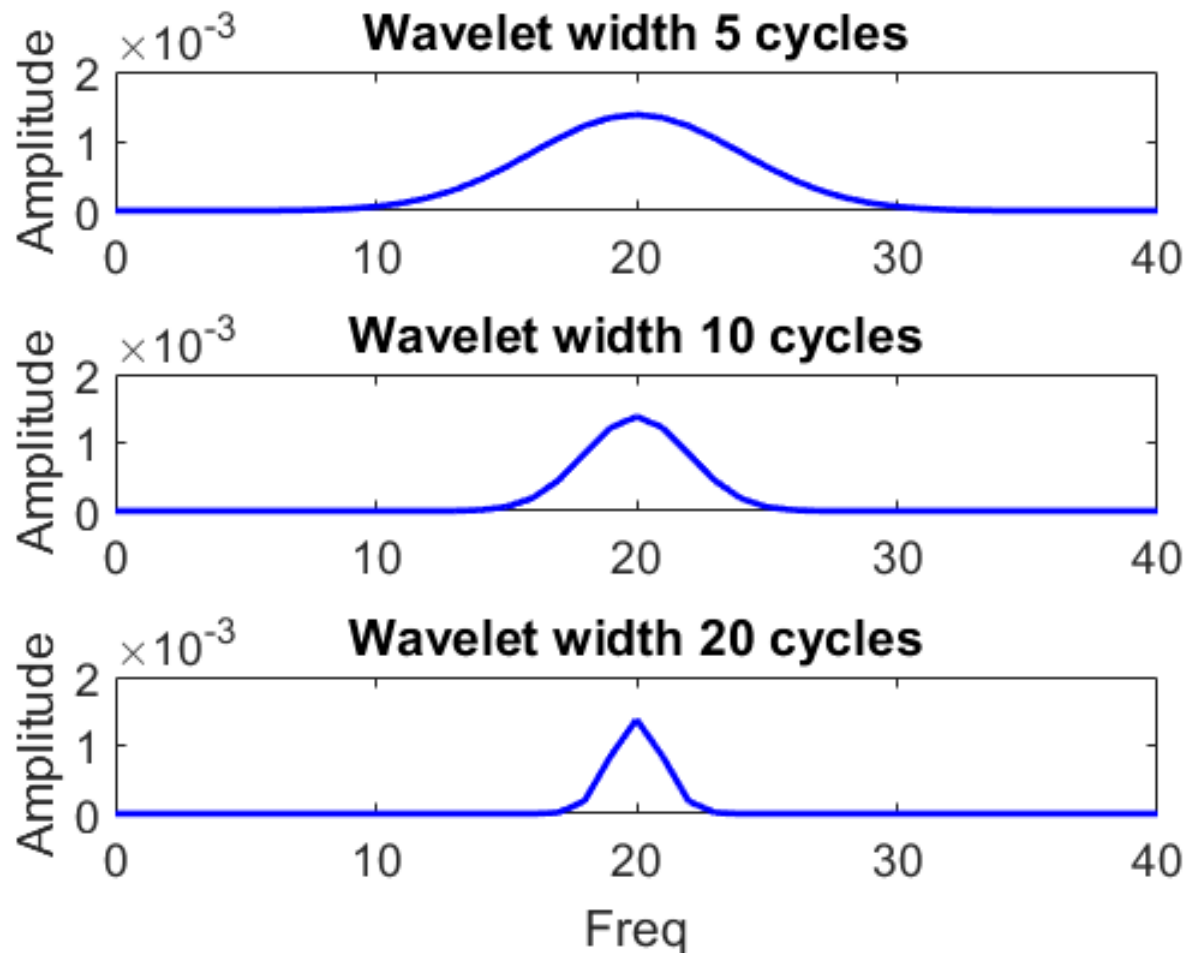
Como funciona a transformação

- Influência do número de ciclos na largura da gaussiana (figura mostra somente parte real da função)



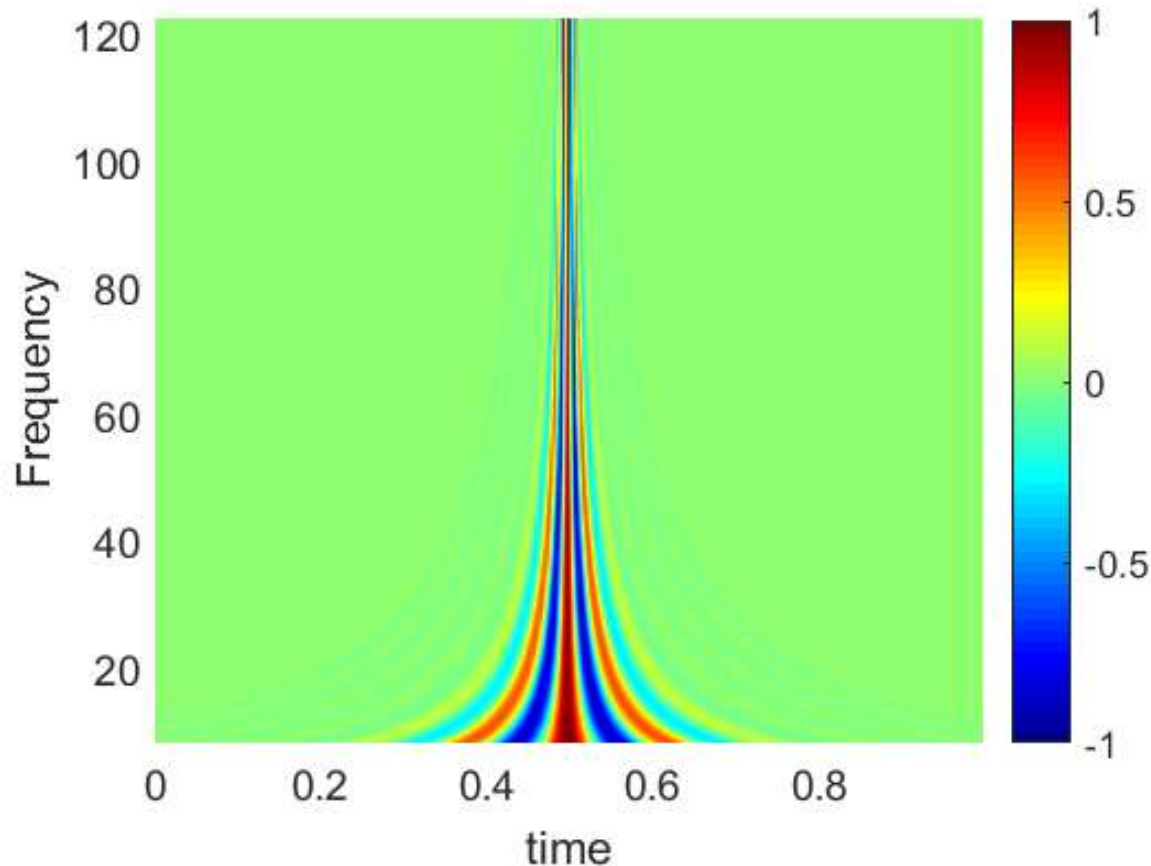
Como funciona a transformação

- Influência do número de ciclos na largura da gaussiana (figura mostra somente parte real da função)




Como funciona a transformação

- Definido o número de ciclos dentro do envelope, pode-se observar como ficam as ondas $\psi_{s,\tau=0.5}(t)$



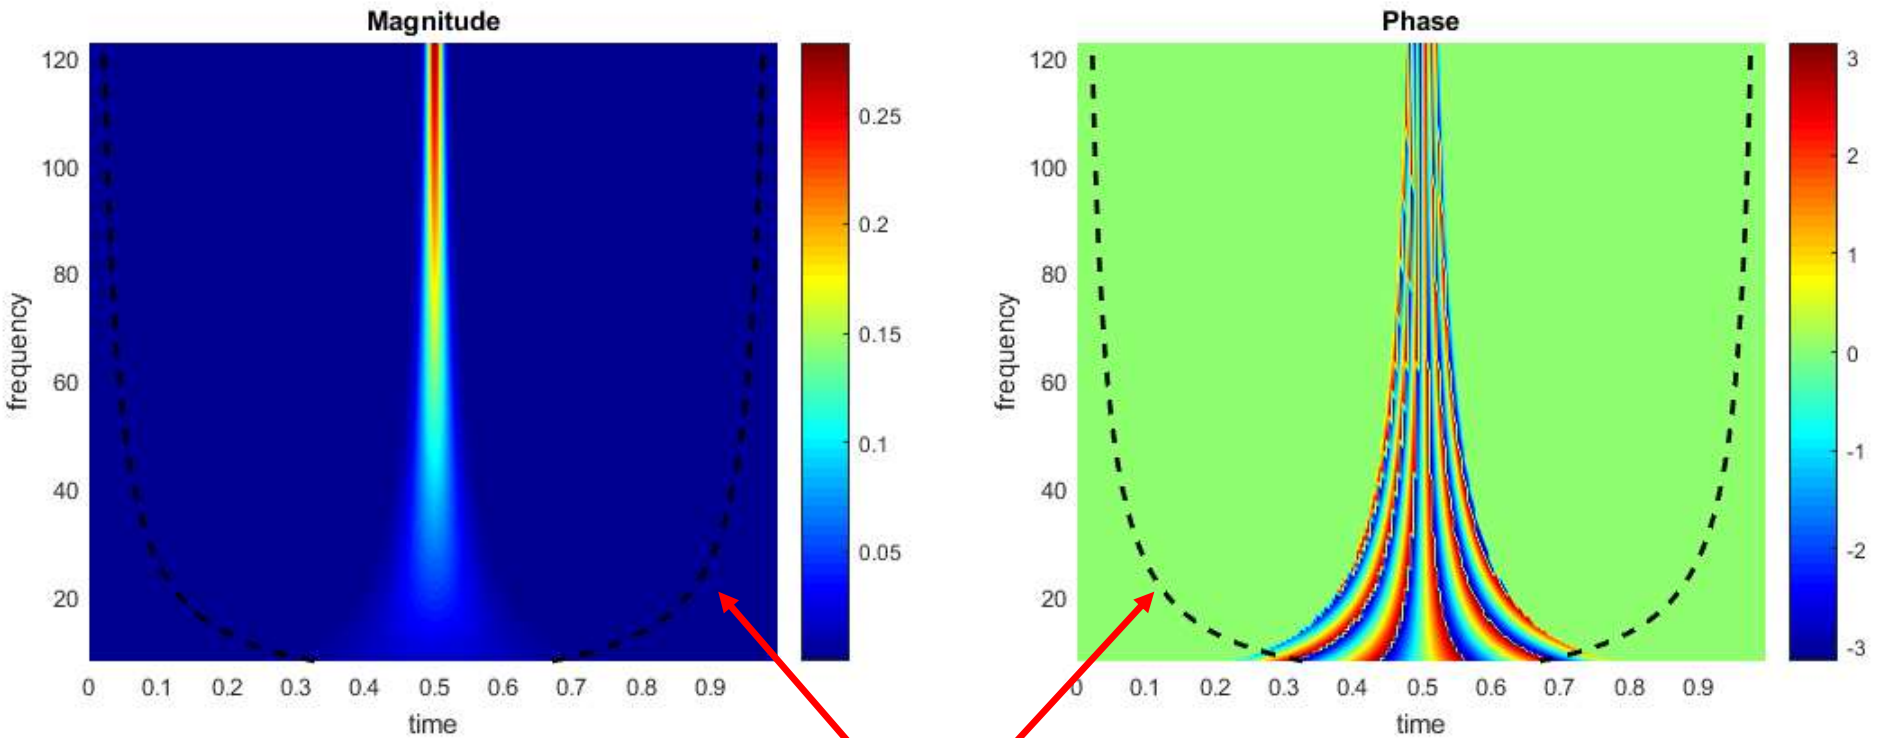
Exemplo

- Fazendo a transformada wavelet de uma função conhecida.
Ex.: delta de Dirac



Exemplo

➤ Transformada Wavelet




Cone de influência - COI

- As bordas do domínio influenciam os resultados da análise. A região abaixo das linhas tracejadas indicam essa região de influência

Exemplo


- Cone de Influência. Para estimar a região de influência, pode-se efetuar a transformada de dois pulsos, sendo um no início e outro no final da série de dados.



Para algumas funções, encontra-se um tempo de decaimento característico (teórico) que depende do tamanho da escala de dilatação do tempo

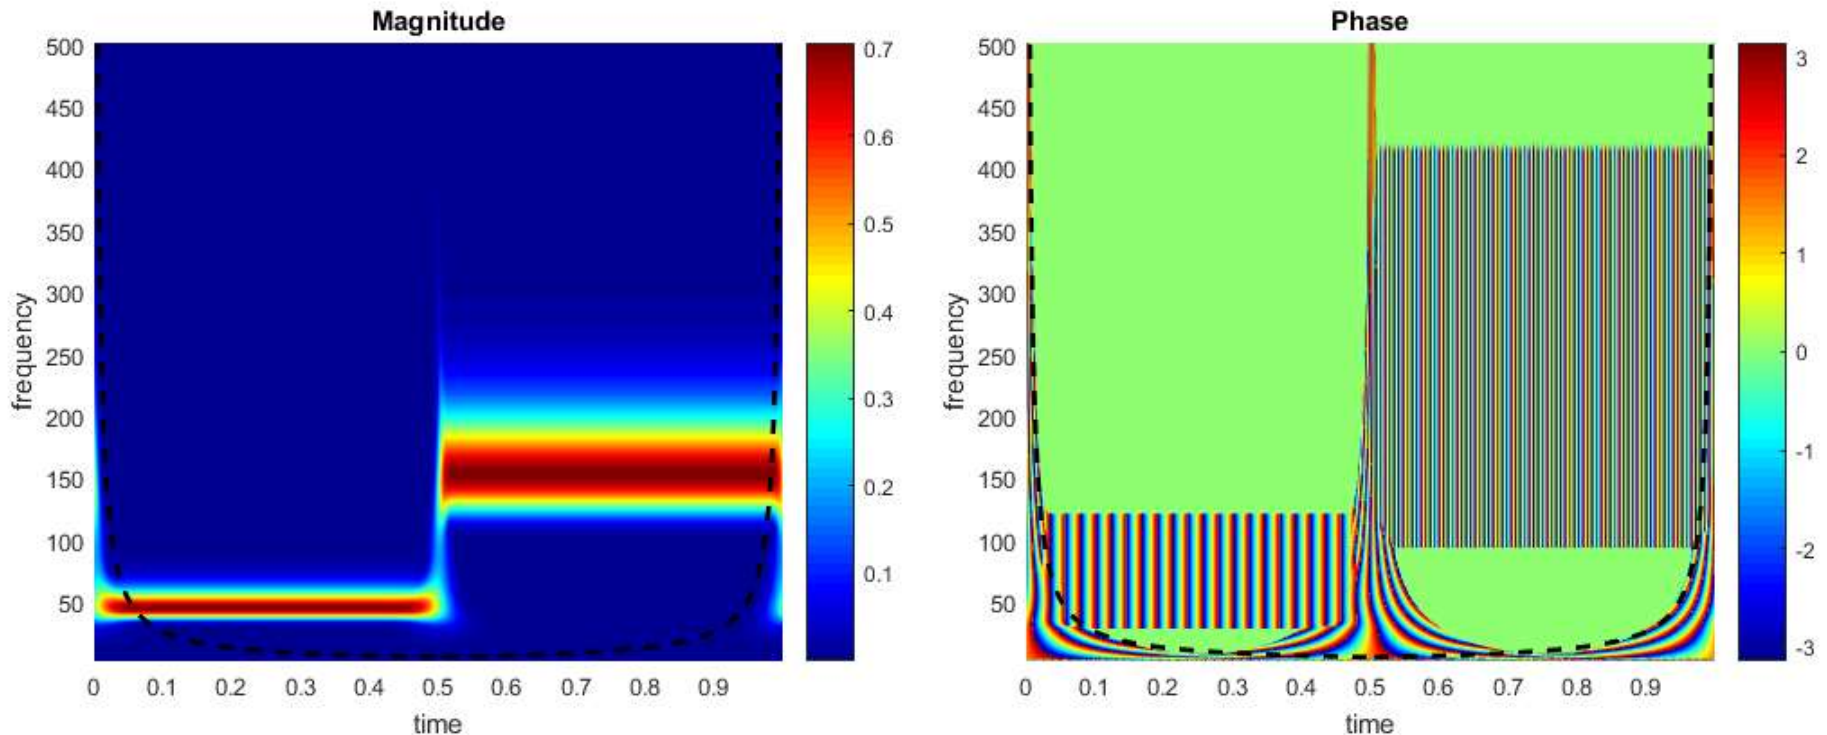
Exemplo 2

➤ Sinal conhecido



Exemplo 2

- CWT – Morlet Complexa. 6 ciclos por janela



Obs: Critério limite para fase (se amplitude menor que 0.5% do máximo, não mostrar fase)



Código

```
function [wt,fc] = wavelet_class(y,fs,a0,ns)
%*****
%           Function for Demonstration of
%           Continuous Wavelet Transform
%*****
% Created by I B de Paula, PUC-Rio 2019,
% Signal processing lecture
% Last Review 17- Jun 2019
%*****
% INPUT DATA
% y           - data time series vector
% fs          - sampling frequency
% a0          - frequency ratio between consecutive scales ;
% ns         - number of scales
% mwtpe (not used) - Mother wavelet type ('ex. Morlet, etc')
%*****
n_cycles=[6]; % number of cycles per wavelet window
%           (minimum 6 for admissibility of Morlet wavelet)
%           see Farge, Annual Rev. Fluid Mech 1992
dt=1/fs;
time=0:dt:(length(y)-1)*dt;
freq=fftshift(-fs/2:fs/length(time):fs/2-fs/length(time));
```



Código

```
fft_y=(fft(y-mean(y))); % FFT of signal for calculation of CWT
% definition of scales based on input parameters
scales=1./(a0.^(ns:-1:1));
% if scale =1 then the last frequency is equals to Nyquist
fc=(scales)*fs/2; % aproximate central frequencies for Morlet wavelet
for i=1:length(fc)
    s = n_cycles/(2*pi*fc(i)); % width of gaussian function
    % dilated wavelet. It is not necessary to translate
    % because the convolution is performed in Fourier space
    t=time-time(end/2); % centralization of wavelet
    psi=fftshift(exp(sqrt(-1)*2*pi*fc(i).*t).*exp(...
        -t.^2./(2*s^2)));
    % fftshift removes time delay introduced for centering
    %Fourier transform of wavelet function
    psi_f=(fft(psi));
    c=sum(abs(psi_f).^2)/length(psi_f); % factor c for
    %normalization of wavelets - all have the same energy
    psi_f=psi_f/c;
    %convolution with data series and inverse Fourier Transform
    convol=(ifft((conj(psi_f).*fft_y))); %
    wt(:,i)=convol(:); % Continuous Wavelet Coefficient
end
return
```


Funções de enjanelamento

| Name | $\psi_0(\eta)$ | $\hat{\psi}_0(s\omega)$ | <i>e</i> -folding time τ_s |
|-------------------------------------|---|--|---------------------------------|
| Morlet (ω_0 = frequency) | $\pi^{-1/4} e^{i\omega_0\eta} e^{-\eta^2/2}$ | $\pi^{-1/4} H(\omega) e^{-(s\omega - \omega_0)^2/2}$ | $\sqrt{2}s$ |
| Paul (m = order) | $\frac{2^m i^m m!}{\sqrt{\pi}(2m)!} (1 - i\eta)^{-(m+1)}$ | $\frac{2^m}{\sqrt{m(2m-1)!}} H(\omega) (s\omega)^m e^{-s\omega}$ | $s/\sqrt{2}$ |
| DOG (m = derivative) | $\frac{(-1)^{m+1}}{\sqrt{\Gamma\left(m + \frac{1}{2}\right)}} \frac{d^m}{d\eta^m} \left(e^{-\eta^2/2} \right)$ | $\frac{i^m}{\sqrt{\Gamma\left(m + \frac{1}{2}\right)}} (s\omega)^m e^{-(s\omega)^2/2}$ | $\sqrt{2}s$ |


$H(\omega)$ = Heaviside step function, $H(\omega) = 1$ if $\omega > 0$, $H(\omega) = 0$ otherwise.

DOG = derivative of a Gaussian; $m = 2$ is the Marr or Mexican hat wavelet.


Funções de enjanelamento

- Existem inúmeras funções wavelets, cada uma com características que podem ser importantes para diferentes aplicações.

ex.: Morlet wavelet




Mexican hat




Funções de enjanelamento

- Existem inúmeras funções wavelets, cada uma com características que podem ser importantes para diferentes aplicações.

ex.: Morlet wavelet



Paul



2th order

Aplicações

- Existem inúmeras funções wavelets, cada uma com características que podem ser importantes para diferentes aplicações.
- Dentre as aplicações desse tipo de transformação, destacam-se (incluindo-se a transformada discreta, que não foi abordada nessa aula):
 - Processamento de sinais e compressão (transformada discreta). JPEG, Video Streaming, etc
 - Visão computacional e biometria
 - Comunicação
 - Biotecnologia, facilita o reconhecimento de mudanças de padrões

Aplicações

- Medicina - análise de sinais de EEG, ECG, EMG e processamento de imagens de ressonância magnética e raio-X
- Análise de dados sísmicos
- Mercado financeiro
- Controle e instrumentação
- Cálculo
- Dinâmica de escoamentos e turbulência
- Astronomia
- Etc... (*On Applications of Wavelets in Engineering and Technology, 2015*)

Aplicações

- Observa-se que as aplicações da técnica são inúmeras.
- As vantagens na compactação de dados não são observadas na análise da transformada contínua, mas ficam evidentes na transformação discreta.

Exercícios

- Revisão sobre aplicação de wavelets no tema de estudo de cada aluno
- Análise wavelet de um sinal do tipo chirp (parâmetros de análise e de geração ficam a cargo de cada aluno).