



Ciências
ULisboa

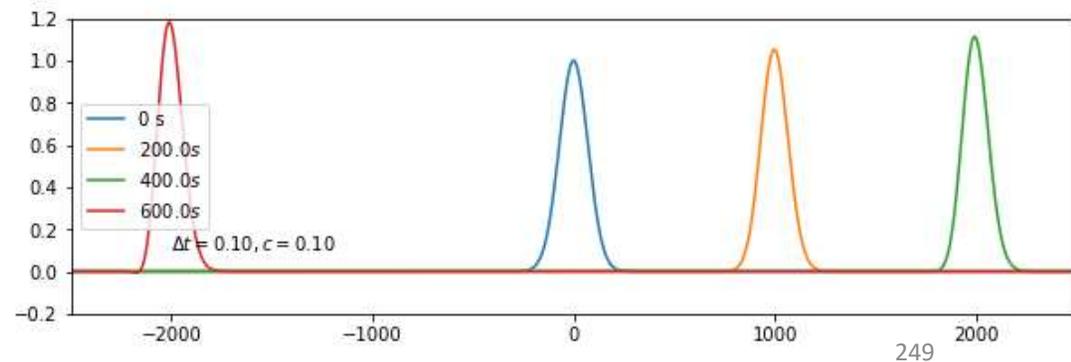
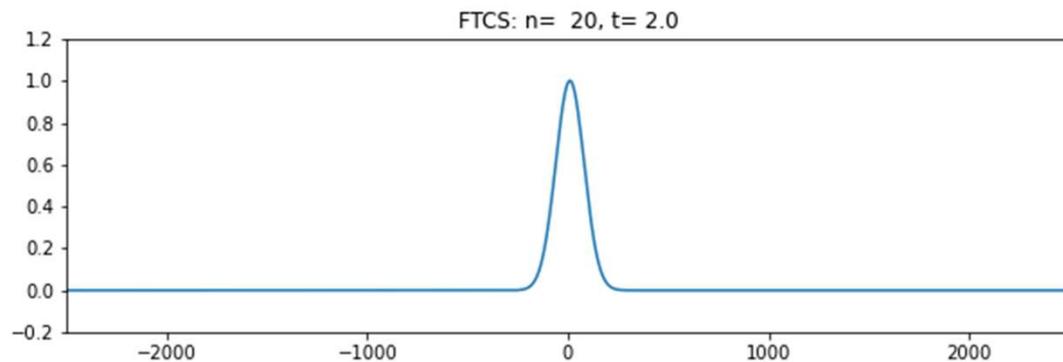
Modelação Numérica

Aula 13

Equação de advecção linear. Método de Lax

Agora com um filme...

```
...
import imageio
import os
...
movie=20
frames=[]
for it in range(1,nt):
    ...
    if it%movie==0:
        plt.figure(2,figsize=(10,3))
        plt.plot(x,T);
        plt.axis([-Lx,Lx,-0.2,1.2])
        plt.title('FTCS: n=%4i, t=%4.1f' %(it,dt*it))
        fn='mov'+str(it)+'.png'
        plt.savefig(fn); plt.clf()
        frames.append(fn)
...
images=[]
for frame in frames:
    images.append(imageio.imread(frame))
    os.remove(frame)
imageio.mimsave('FTCS'+'.gif',images,duration=0.1)
```



O método de Euler (FTCS) é **incondicionalmente** instável

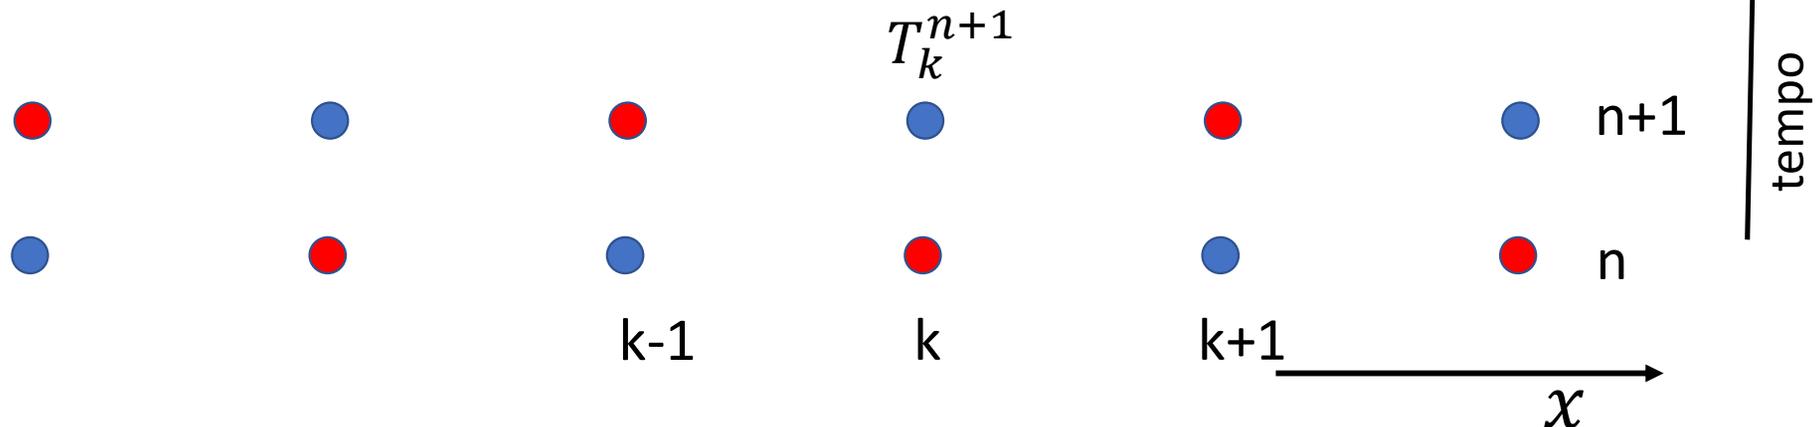
A instabilidade é neste caso **independente** da escolha dos parâmetros de discretização ($\Delta t, \Delta x$) e não é uma consequência da ordem da aproximação. É possível definir esquemas de 1ª ordem (ou ordem mais elevada) condicionalmente estáveis.

Aproximação de Lax

Em vez de $T_k^{n+1} = T_k^n - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$

Fazemos: $T_k^{n+1} = \frac{1}{2}(T_{k-1}^n + T_{k+1}^n) - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$

Continua a ser um método com 1 nível temporal e de primeira ordem no tempo e segunda no espaço.



LAX

```
...
for it in range(1,nt):
    for ix in range(1,nx-1):
        TP[ix]=0.5*(T[ix-1]+T[ix+1])-u*dt/(dx*2)*(T[ix+1]-T[ix-1])
    TP[nx-1]=0.5*(T[nx-2]+T[0])-u*dt/(dx*2)*(T[0]-T[nx-2]) #fronteira cíclica
    TP[0]=0.5*(T[1]+T[nx-1])-u*dt/(dx*2)*(T[1]-T[nx-1]) #fronteira cíclica
    T=np.copy(TP) #update temporal
```

...

FTCS

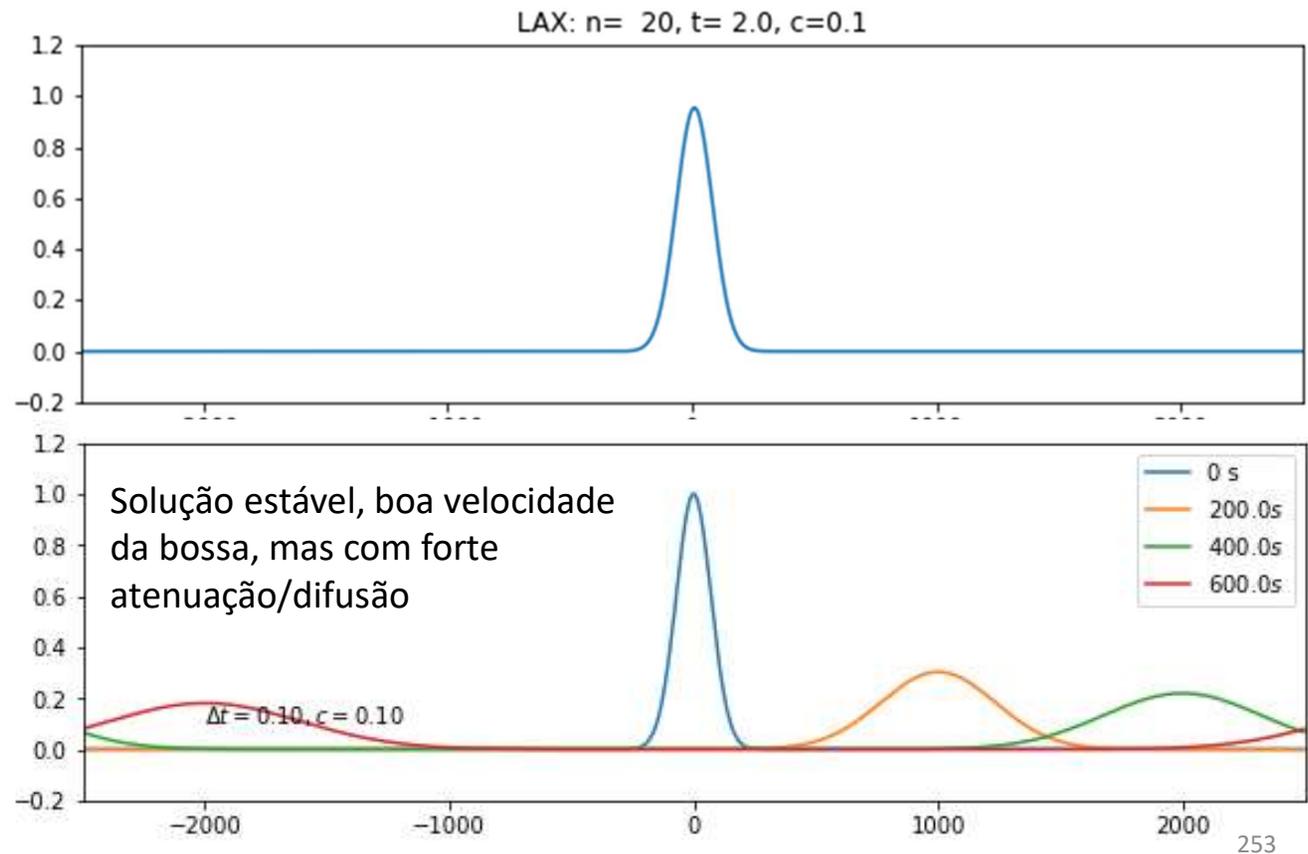
```
for it in range(1,nt):
    for ix in range(1,nx-1):
        TP[ix]=T[ix]-u*dt/(dx*2)*(T[ix+1]-T[ix-1])
    TP[nx-1]=T[nx-1]-u*dt/(dx*2)*(T[0]-T[nx-2]) #fronteira cíclica
    TP[0]=T[0]-u*dt/(dx*2)*(T[1]-T[nx-1]) #fronteira cíclica
    T=np.copy(TP) #update temporal
```

LAX Courant=0.1: difusão numérica

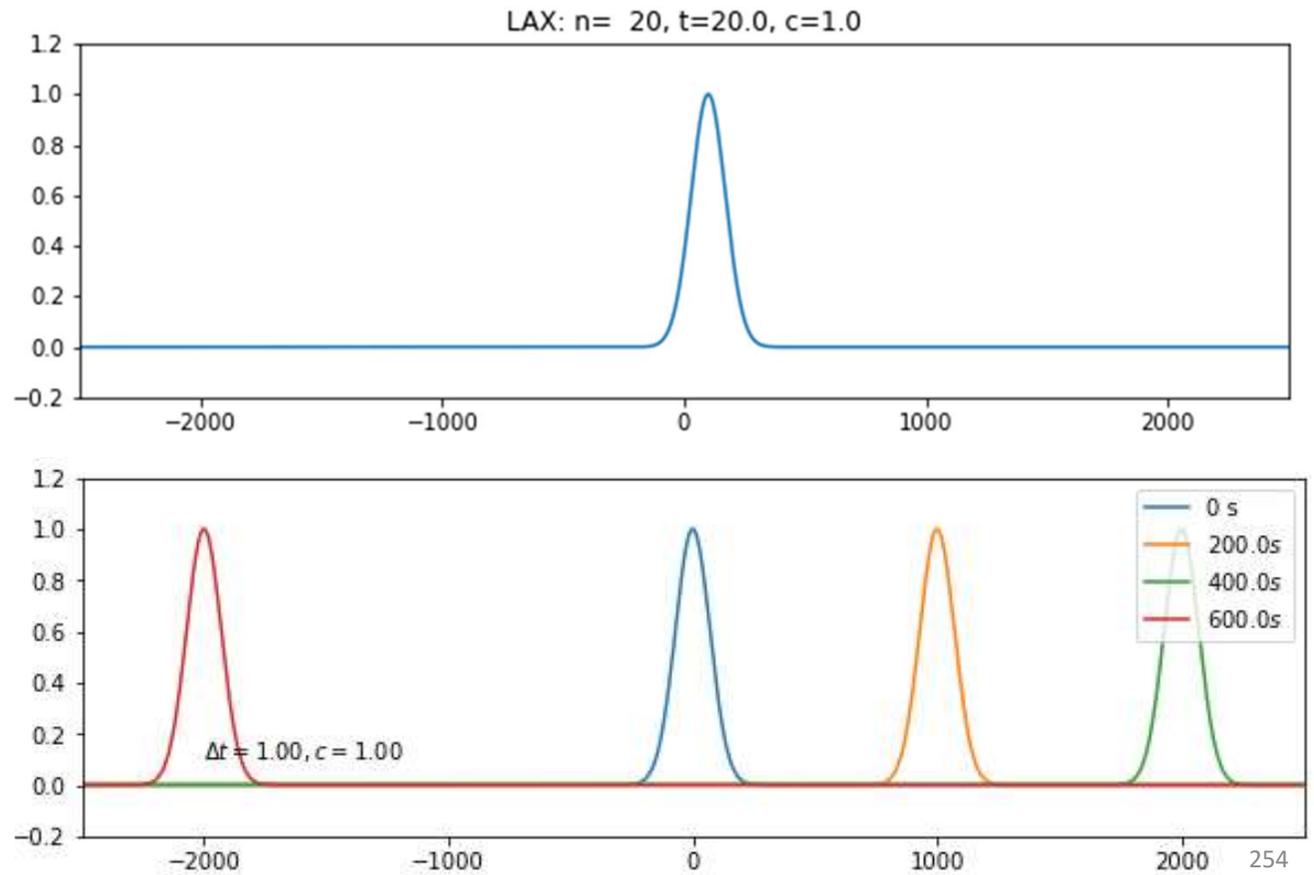
O comportamento do método depende do Número de Courant (of de Courant–Friedrichs–Lewy, CFL)

$$c = \frac{u\Delta t}{\Delta x}$$

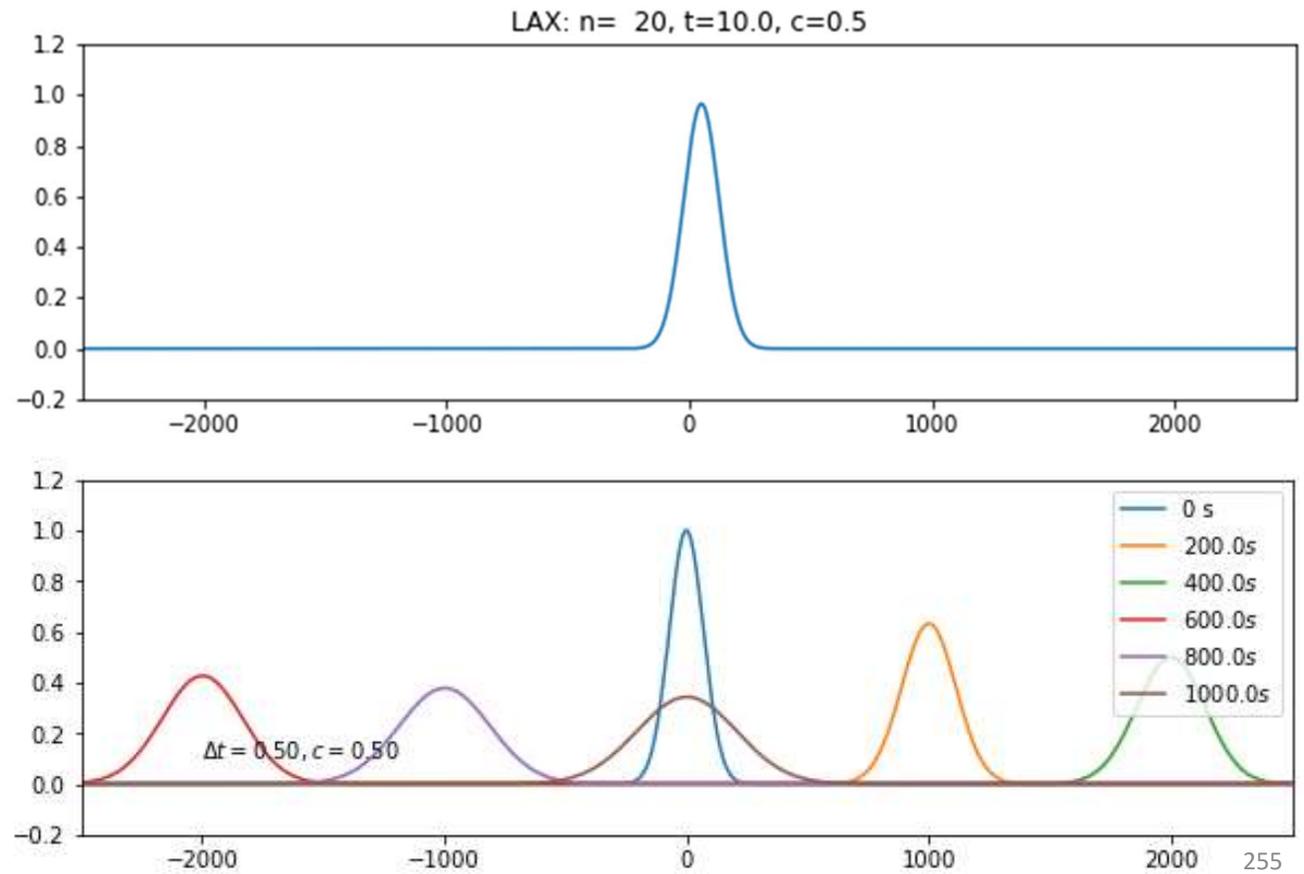
Notar que c é adimensional.



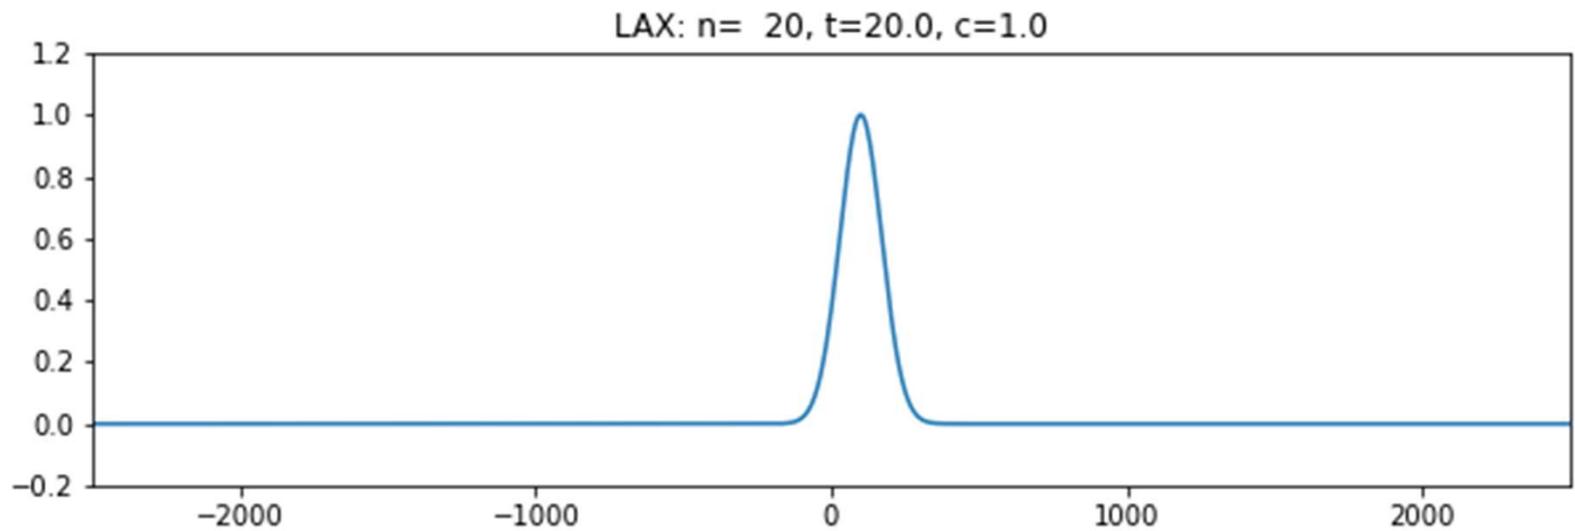
LAX Courant=1.0: sem atenuação



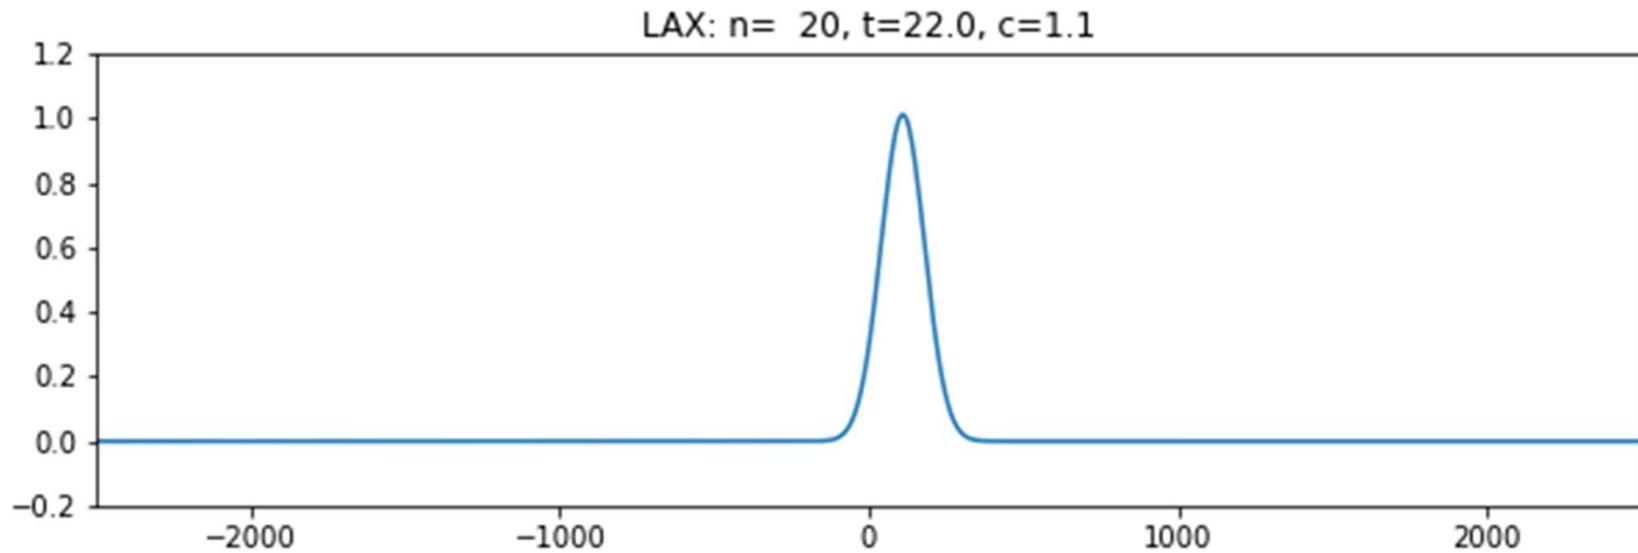
LAX Courant=0.5



LAX Courant=1.0: 5 voltas... perfeito?



LAX Courant=1.1: **instável**



O método de LAX

É **condicionalmente estável**: se $c \leq 1$ ($c = \frac{u\Delta t}{\Delta x}$) c é o **número de Courant** (ou CFL)

É **exato** para $c = 1$. Mas **atenua as pequenas escalas** se $c < 1$. No caso da equação de advecção linear ($u = \text{const}$) é fácil escolher $c = 1$.

Em geral não é possível fazer isso, mas deve evitar-se um c pequeno pois a difusão (numérica) será elevada.

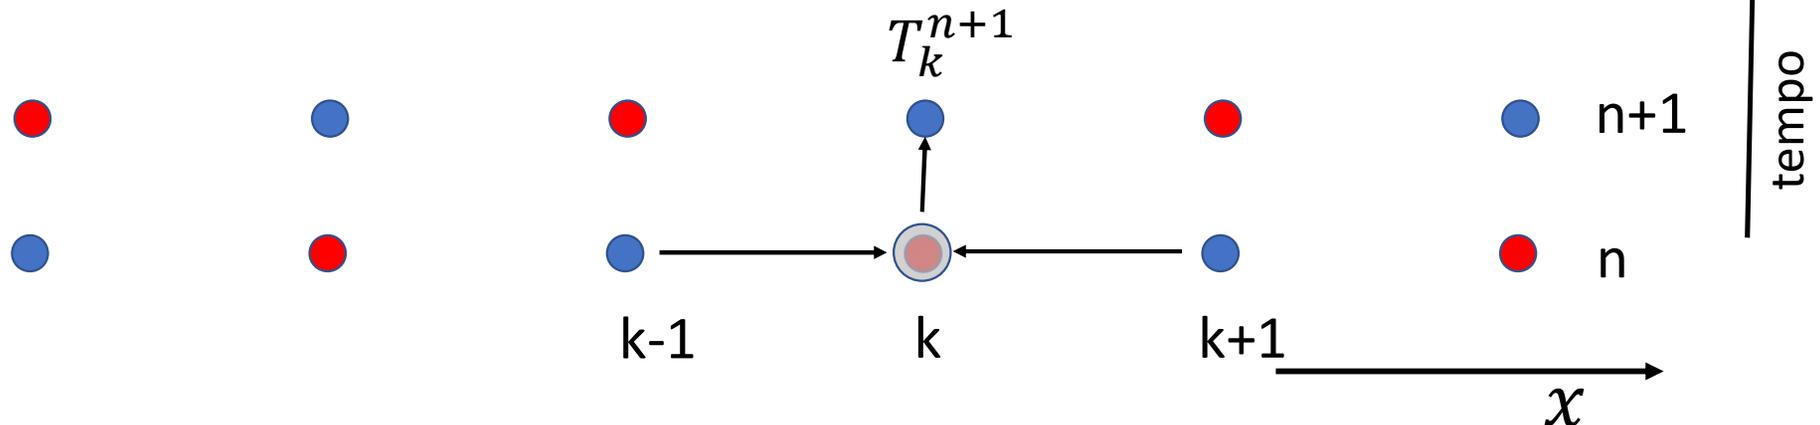
Notem que o $c \leq 1$ pode ser lida como a condição de que, em cada passo de tempo (Δt), a propagação da informação ($l = u\Delta t$) não pode exceder um passo de grelha espacial ($l \leq \Delta x$). **No caso da equação de advecção linear a informação propaga-se à velocidade do fluido (u)**. Noutros casos pode propagar-se mais rapidamente, nomeadamente na forma de uma onda.

Aproximações FCTS e Lax

$$\text{FTCS: } T_k^{n+1} = T_k^n - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$$

$$\text{Lax: } T_k^{n+1} = \frac{1}{2}(T_{k-1}^n + T_{k+1}^n) - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$$

Continua a ser um método com 1 nível temporal e de primeira ordem no tempo e segunda no espaço.



O método de LeapFrog

$$\text{FTCS: } T_k^{n+1} = T_k^n - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$$

$$\text{Lax: } T_k^{n+1} = \frac{1}{2}(T_{k-1}^n + T_{k+1}^n) - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$$

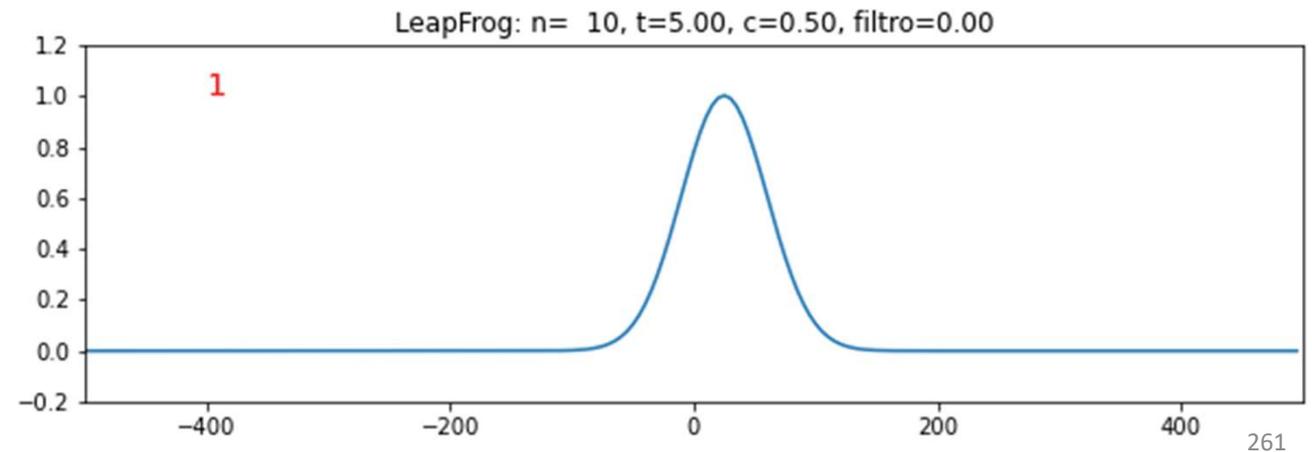
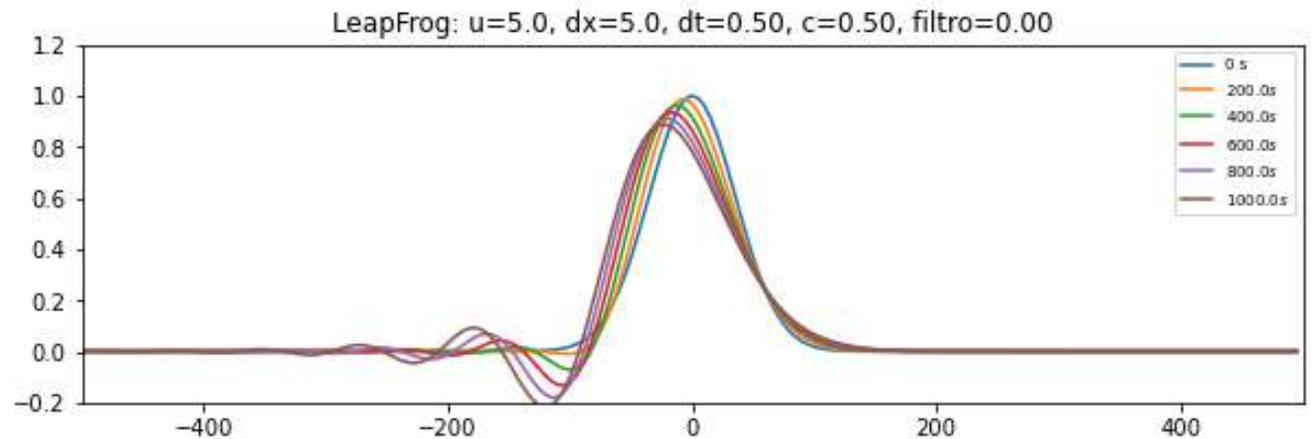
$$\text{LeapFrog: } T_k^{n+1} = T_k^{n-1} - u2\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{2\Delta x}$$

No caso do LeapFrog é preciso conhecer dois passos de tempo anteriores ($n - 1, n$) para calcular o estado futuro ($n + 1$).

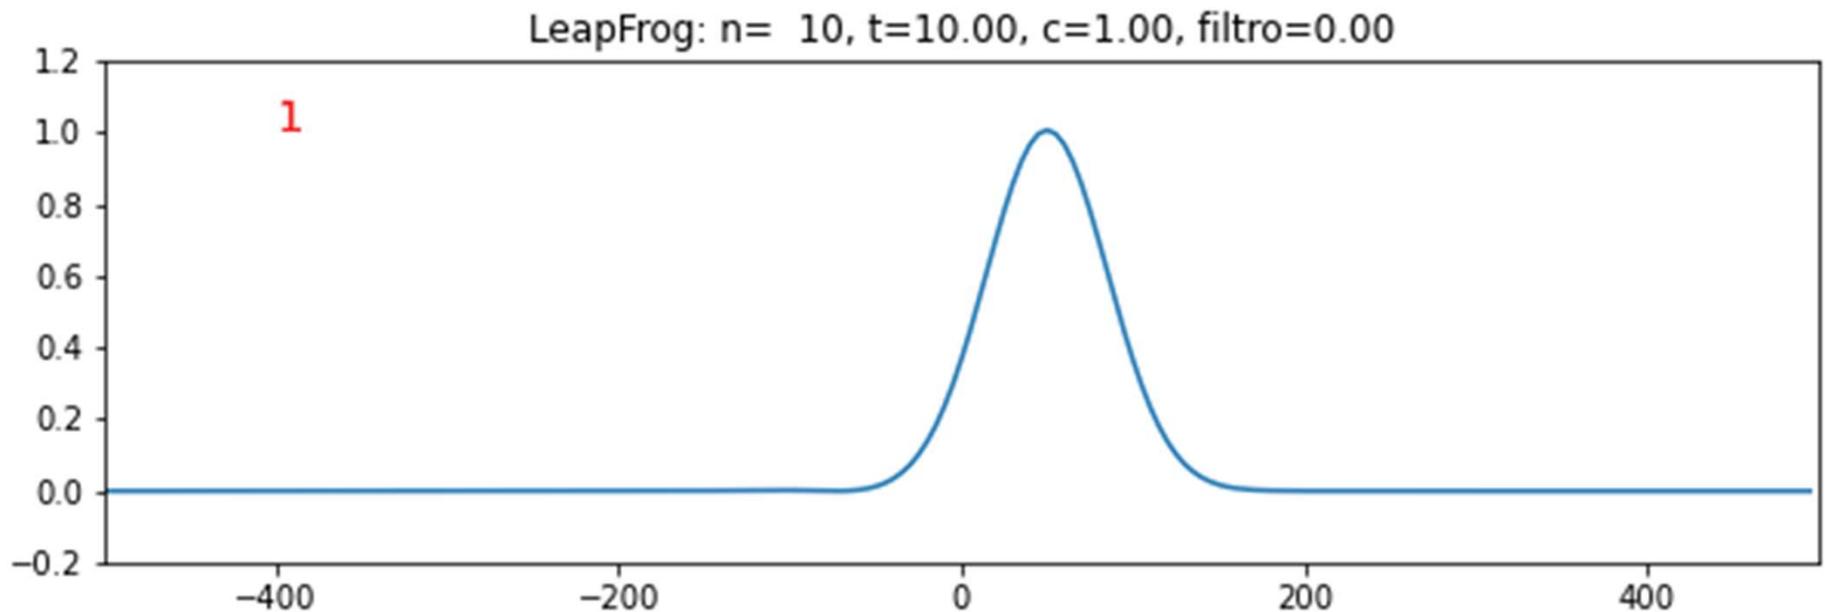
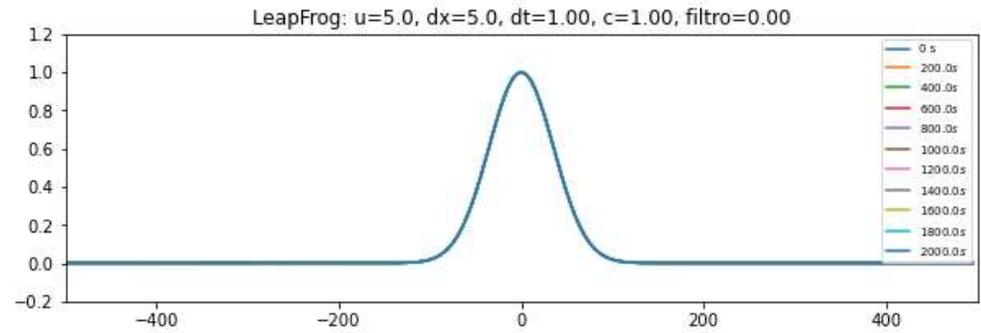
Leapfrog $c = 0.5$ dispersão numérica

Ao longo do tempo a bossa vai-se alargando, com oscilações de pequeno comprimento de onda a deslocarem-se mais lentamente: a isto chama-se **dispersão** (numérica).

Num sistema **dispersivo** a velocidade depende do comprimento de onda.



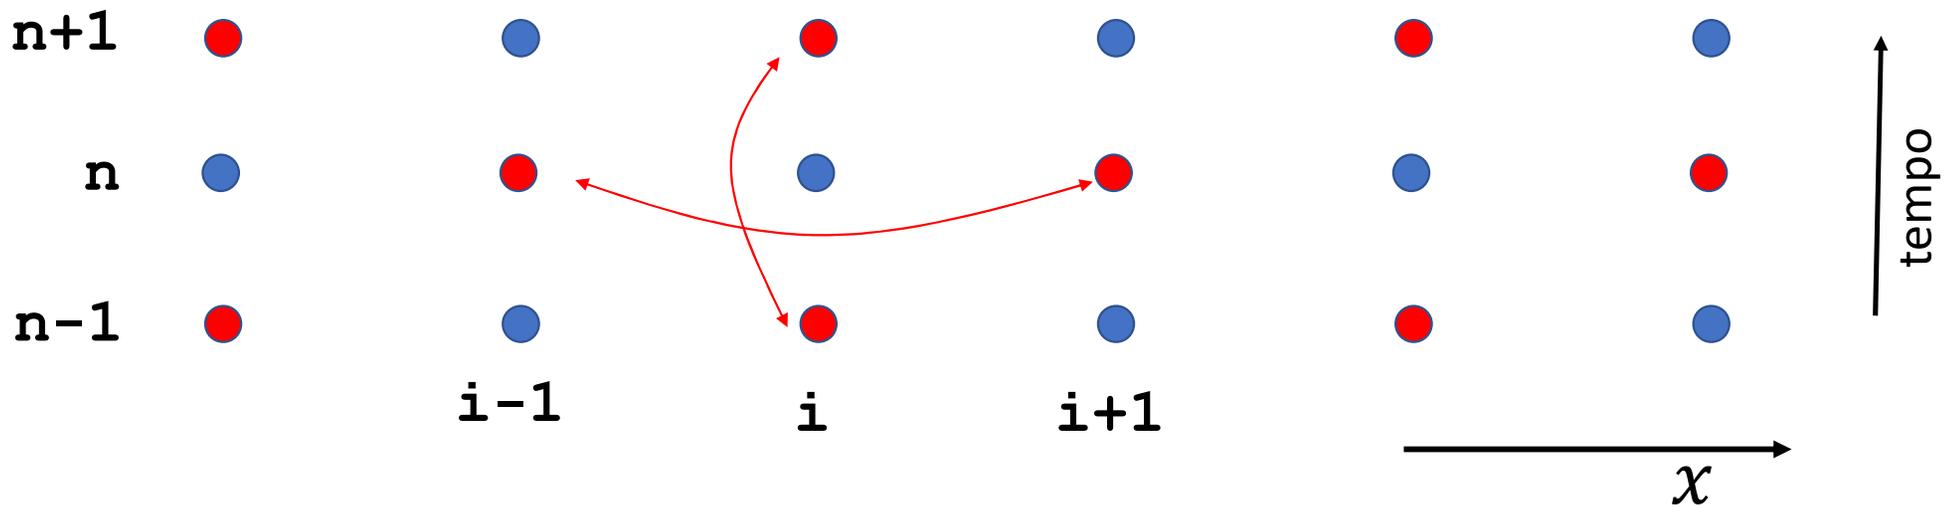
LeapFrog $c = 1$ (10 voltas): perfeito!



LeapFrog

$$T_k^{n+1} = T_k^{n-1} - u\Delta t \frac{T_{k+1}^n - T_{k-1}^n}{\Delta x}$$

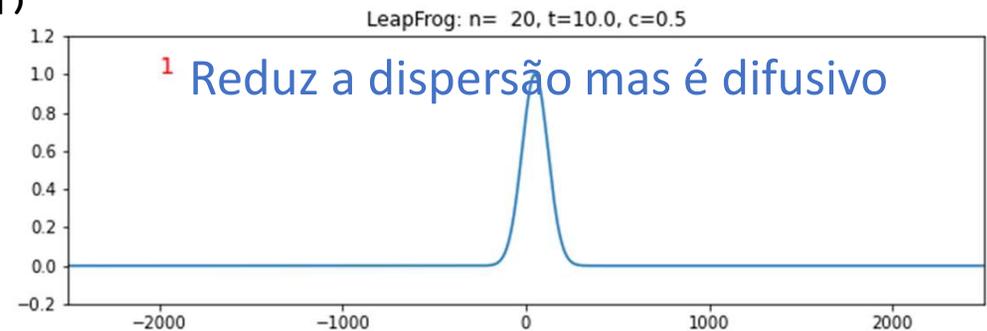
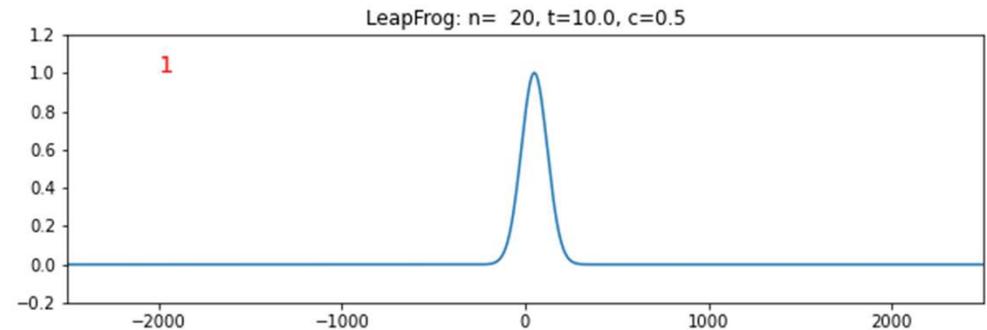
A malha computacional divide-se em conjuntos (pontos vermelhos e azuis) que não comunicam entre si. As malhas tendem a **desacoplar, criando ruído**.



LeapFrog $c = 0.5$ (10 voltas): dispersivo

```
#Filtro temporal
asel=0.05 #asel=0 desliga o filtro
timefil=[asel,1-2*asel,asel]

for it in range(2,nt):
    for ix in range(1,nx-1):
        TP[ix]=TM[ix]-u*dt/(dx)*(T[ix+1]-T[ix-1])
    TP[nx-1]=TM[nx-1]-u*dt/(dx)*(T[0]-T[nx-2])
    TP[0]=TM[0]-u*dt/(dx)*(T[1]-T[nx-1])
    T=timefil[0]*TM+timefil[1]*T+timefil[2]*TP
    TM=np.copy(T);T=np.copy(TP)
```



Com o filtro temporal reduzem-se as oscilações de pequeno c.d.o (**menos dispersão**), mas a bossa perde amplitude a alarga (**difusão**)

Numa próxima aula

Faremos a discussão mais aprofundada das propriedades destes 2 esquemas (Lax e Leapfrog).

Antes disso vamos pensar na advecção a duas dimensões.

Advecção 2D

Equação na forma de fluxo

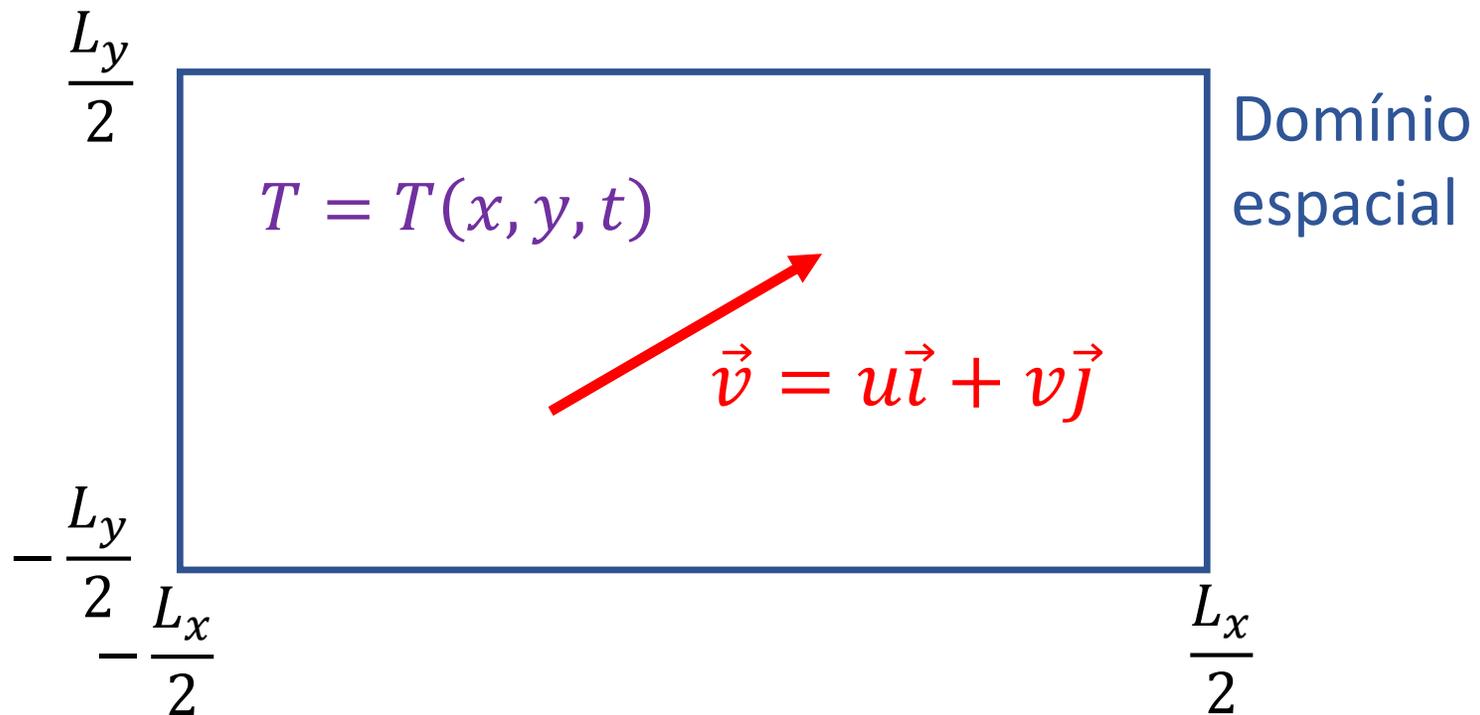
$$\frac{\partial T}{\partial t} = -u \frac{\partial T}{\partial x} - v \frac{\partial T}{\partial y} \Rightarrow \frac{\partial T}{\partial t} = -\frac{\partial uT}{\partial x} - \frac{\partial vT}{\partial y}.$$

A forma de fluxo é exata em duas condições:

$u, v = \text{const}$ (advecção linear)

ou

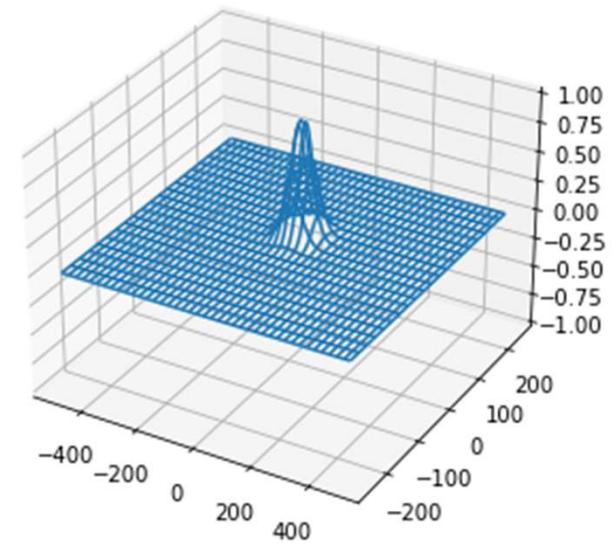
$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} = 0$ (fluido incompressível)



Advecção 2D Leapfrog (1, wireframe)

```
import numpy as np
import matplotlib.pyplot as plt
import imageio
import os
from mpl_toolkits.mplot3d import axes3d

def graf(xis, yps, zed, it, tit):
    fig=plt.figure(2,figsize=(10,10))
    ax = fig.add_subplot(111, projection='3d')
    ax.plot_wireframe(xis, yps, zed, rstride=5, cstride=5)
    ax.set_zlim3d(-1,1)
    plt.title(tit)
    fn='mov'+str(it)+'.png'
    plt.savefig(fn)
    plt.clf()
    return fn
```



Advecção 2D Leapfrog (2, preliminares)

```
...
nx=200;dx=5;Lx=nx/2*dx;ny=100;dy=dx;Ly=ny/2*dy #grelha
u=5;v=10;dt=0.3
nvolta=int(2*Lx/u/dt); nt=nvolta*1+1; passo=nvolta
asel=0.0; timefil=[asel,1-2*asel,asel]
x=np.arange(-Lx,Lx,dx);y=np.arange(-Ly,Ly,dy)
xis=np.zeros((nx,ny));yps=np.zeros((nx,ny))
for iy in range(ny):
    xis[:,iy]=x
for ix in range(nx):
    yps[ix,:]=y
movie=10; frames=[]
courant=np.sqrt(u**2+v**2)*dt/(np.sqrt(dx**2+dy**2)/2)
Wx=50;x0=0;Wy=30;y0=0
TI=np.exp(-((xis-x0)/Wx)**2-((yps-y0)/Wy)**2) #perturbação inicial
T=np.copy(TI);TP=np.copy(T);TM=np.copy(T)
```

#xis, yps são arrays 2d

Advecção 2D Leapfrog (3, 1º passo)

```
...
#1º passo Euler
for ix in range(nx):
    ixm=ix-1;ixp=ix+1
    if ixm<0:
        ixm=nx-1
    elif ixp>nx-1:
        ixp=0
    for iy in range(ny):
        iym=iy-1;iyp=iy+1
        if iym<0:
            iym=ny-1
        elif iyp>ny-1:
            iyp=0
        T[ix,iy]=TM[ix,iy]-u*dt/(2*dx)*(TM[ixp,iy]-TM[ixm,iy])- \
            v*dt/(2*dx)*(TM[ix,iyp]-TM[ix,iym])
```

Advecção 2D Leapfrog (4, leapfrog)

```
...
for it in range(2,nt):
    for ix in range(nx): #percorre-se todos os pontos
        ixm=ix-1;ixp=ix+1
        if ixm<0:
            ixm=nx-1           Condição
                               fronteira cíclica
        elif ixp>nx-1:
            ixp=0
        for iy in range(ny):
            iym=iy-1;iyp=iy+1
            if iym<0:
                iym=ny-1       Condição fronteira
                               cíclica
            elif iyp>ny-1:
                iyp=0
            TP[ix,iy]=TM[ix,iy]-u*dt/dx*(T[ixp,iy]-T[ixm,iy])-
                v*dt/dy*(T[ix,iyp]-T[ix,iym])
    T=timefil[0]*TM+timefil[1]*T+timefil[2]*TP #filtro temporal
    TM=np.copy(T);T=np.copy(TP) #update temporal
```

Advecção 2D Leapfrog (5, movie)

```
...
    if it%movie==0:
        tit=r'$Adv.Lin. by. LeapFrog: u=%3.1f, v=%3.1f, c=%3.2f, \
            filtro=%3.2f, t=%4.0f s $' % (u,v,courant,asel,it*dt)
        fn=graf(xis,yps,T,it,tit)
        frames.append(fn)

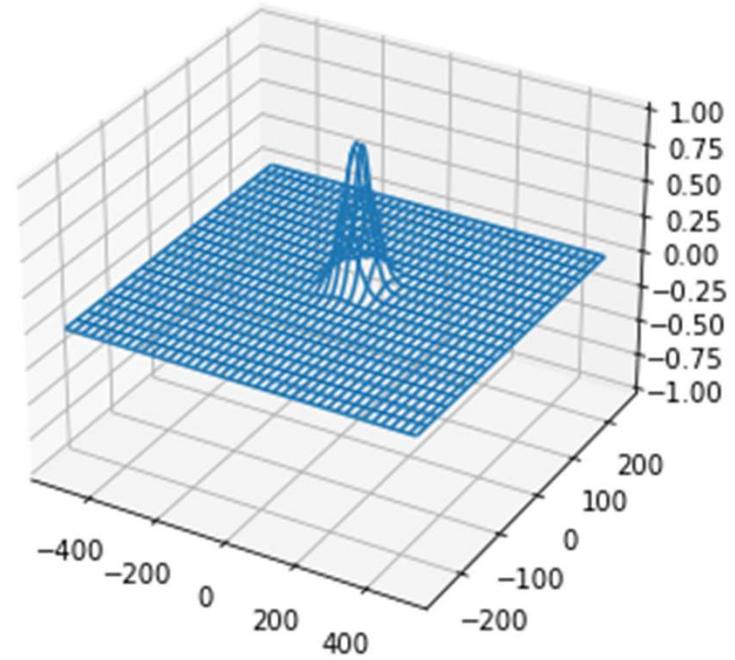
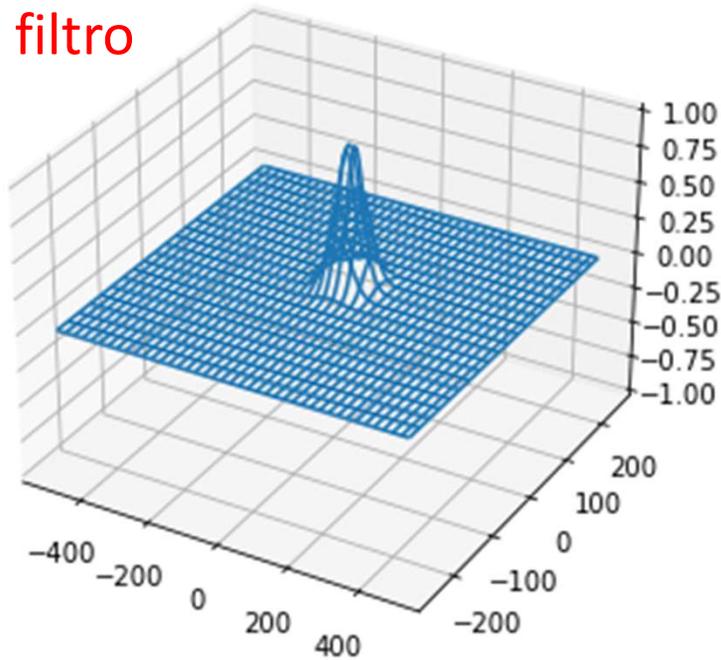
images=[] #frames para filme
for frame in frames:
    images.append(imageio.imread(frame))
    os.remove(frame)
imageio.mimsave('ADV2d'+'.gif', images,duration=0.1)
```

Condições cíclicas

Adv. Lin. by. LeapFrog : $u = 5.0, v = 10.0, c = 0.95, filtro = 0.0$ Adv. Lin. by. LeapFrog : $u = 5.0, v = 10.0, c = 0.95, filtro = 0.00, t = 3s$

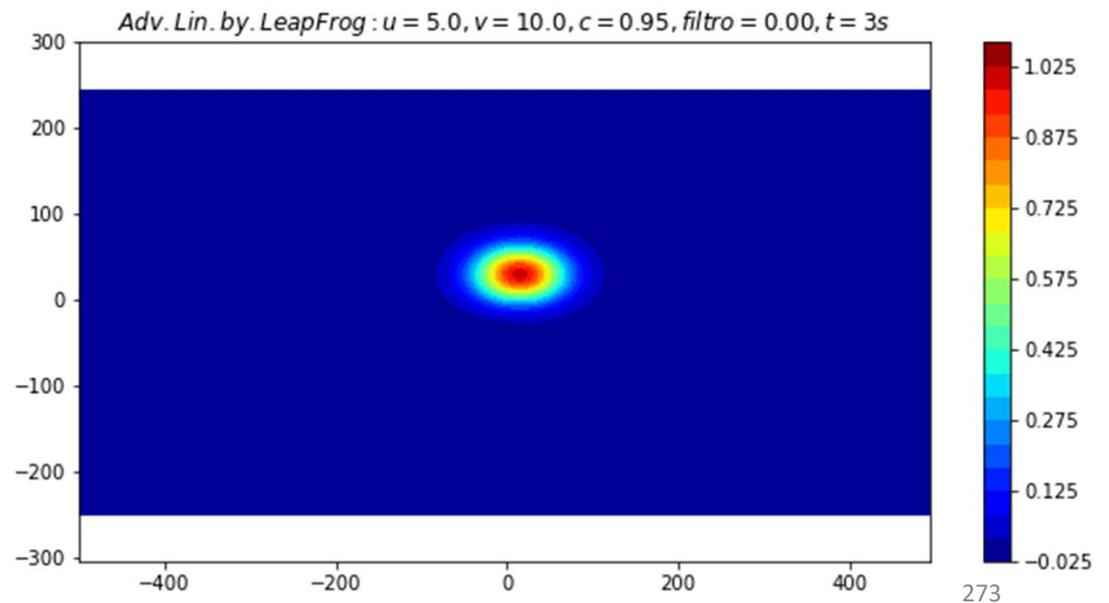
Sem filtro

Com filtro



O output gráfico podia ser diferente

```
def graf(xis, yps, zed, it, tit):  
    plt.figure(2, figsize=(10, 5))  
    map=plt.contourf(xis, yps, zed, cmap='jet', levels=np.arange(-0.025, 1.1, 0.05))  
    plt.colorbar(map)  
    plt.axis('equal')  
    plt.title(tit)  
    fn='mov'+str(it)+'.png'  
    plt.savefig(fn)  
    plt.clf()  
    return fn
```



Propriedades de um método numérico

Consistência: converge para a solução analítica $\lim_{\Delta x, \Delta t \rightarrow 0}$

Precisão: “velocidade” de convergência do erro para zero, e.g. $\mathcal{O}(\Delta t^2)$

Estabilidade/ atenuação/ difusão numérica

Frequentemente, a estabilidade é conseguida com atenuação de pequenos comprimentos de onda: comportamento difusivo.

Velocidade de fase/ Dispersão

Frequentemente, diferentes comprimentos de onda são propagados a diferente velocidade, apesar de isso não resultar de leis físicas: dispersão numérica

Equação de **advecção** (linear,1D) $\frac{\partial T}{\partial t} = -U \frac{\partial T}{\partial x}$

Em geral, se a condição inicial for $T(x, 0) = f(x)$, a solução analítica será $T(x, t) = f(x - Ut)$. O comportamento da solução numérica depende de f .

Podemos estudar as propriedades de um método de solução a partir da análise do comportamento da solução no caso em que a condição inicial é uma senoide (k é o **número de onda**, $k = 2\pi/\lambda$)

$$T(x, 0) = \cos(kx)$$

Com esta condição inicial a solução analítica é:

$$T(x, t) = \cos(k(x - Ut))$$

i.e. a senoide propaga-se à velocidade U , sem deformação.

Análise de estabilidade: Método de von Neumann (ou de Fourier)

Em geral a solução numérica pode ser escrita na forma discreta (omitindo $Re\{\}$):

$$T(x = m\Delta x, t = 0) \approx T_m^0 = e^{ikm\Delta x}$$

No instante $t = n\Delta t$, vamos estudar a solução (numérica) por **separação de variáveis**:

$$T(x = m\Delta x, t = n\Delta t) \approx T_m^n = B^n e^{ikm\Delta x}$$

Em que B é uma constante complexa, cujo valor depende do método numérico utilizado. A **solução analítica** seria recuperada se

$$B^n = e^{-ikUn\Delta} \iff B = e^{-ikU\Delta t}$$

Sendo nesse caso B um complexo de módulo 1 e fase $-kU\Delta t$. No caso geral, se $|B| < 1$ a solução decairá no tempo com B^n , se $|B| > 1$ crescerá **exponencialmente** no tempo e o método é **instável**.

Aplicação ao método de Euler FTCS

$$T_m^{n+1} = T_m^n - U\Delta t \frac{T_{m+1}^n - T_{m-1}^n}{2\Delta x} \text{ com } T_m^n = B^n e^{ikm\Delta x}$$

substituindo

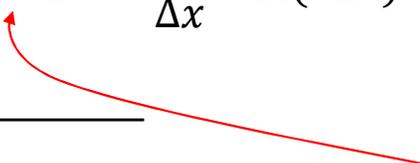
$$B^{n+1} e^{ikm\Delta x} = B^n e^{ikm\Delta x} - \frac{U\Delta t}{2\Delta x} (B^n e^{ik(m+1)\Delta x} - B^n e^{ik(m-1)\Delta x})$$

$$B^{n+1} = B^n - \frac{U\Delta t}{2\Delta x} (B^n e^{ik\Delta x} - B^n e^{-ik\Delta x})$$

$$B = 1 - \frac{U\Delta t}{2\Delta x} (e^{ik\Delta x} - e^{-ik\Delta x}) = 1 - i \frac{U\Delta t}{\Delta x} \sin(k\Delta x)$$

Logo

$$|B| = \sqrt{1 + \frac{U^2 \Delta t^2}{\Delta x^2} \sin^2(k\Delta x)} > 1$$

$$\sin(k\Delta x) = \frac{e^{ik\Delta x} - e^{-ik\Delta x}}{2i}$$


E o método é **absolutamente instável**.



Ciências
ULisboa

Modelação Numérica

Aula 13a (NA)

Análise de estabilidade de esquemas numéricos pelo método de von Neumann (ou de Fourier)

Estabilidade do método de Lax

Método de Lax

$$T_m^{n+1} = \frac{1}{2}(T_{m-1}^n + T_{m+1}^n) - U\Delta t \frac{T_{m+1}^n - T_{m-1}^n}{2\Delta x}$$

Substituindo

$$B^{n+1}e^{ikm\Delta x} = \frac{1}{2}(B^n e^{ik(m-1)\Delta x} + B^n e^{ik(m+1)\Delta x}) - \frac{U\Delta t}{2\Delta x}(B^n e^{ik(m+1)\Delta x} - B^n e^{ik(m-1)\Delta x})$$

Simplificando

$$B = \frac{1}{2}(e^{-ik\Delta x} + e^{ik\Delta x}) - \frac{U\Delta t}{2\Delta x}(e^{ik\Delta x} - e^{-ik\Delta x}) = \cos(k\Delta x) - i \frac{U\Delta t}{\Delta x} \sin(k\Delta x)$$

$$\sin(k\Delta x) = \frac{e^{ik\Delta x} - e^{-ik\Delta x}}{2i}$$

$$\cos(k\Delta x) = \frac{e^{ik\Delta x} + e^{-ik\Delta x}}{2}$$

$$B = \cos(k\Delta x) - i \frac{U\Delta t}{\Delta x} \sin(k\Delta x) \Rightarrow |B| = \sqrt{\cos^2(k\Delta x) + \frac{U^2\Delta t^2}{\Delta x^2} \sin^2(k\Delta x)}$$

Logo, se

$$\frac{U^2\Delta t^2}{\Delta x^2} \leq 1 \Rightarrow |B| \leq 1$$

O método é **condicionalmente estável**, será estável se satisfizer a condição CFL (Courant-Friederichs-Levy): $\frac{U\Delta t}{\Delta x} \leq 1$ (Número de Courant)

Se $\frac{U\Delta t}{\Delta x} = 1$ o método conserva a amplitude original, se $\frac{U\Delta t}{\Delta x} < 1$ o método sofre de **atenuação**, se $\frac{U\Delta t}{\Delta x} > 1$ o método é **instável** (amplitude cresce exponencialmente).

Dispersão no método de Lax

A estabilidade é uma condição necessária para um método ser usável, mas não é suficiente para o caracterizar. Para recuperar a solução analítica exata, seria necessário que

$$B = e^{-ikU\Delta t}$$

No método de Lax temos:

$$B = \cos(k\Delta x) - i \frac{U\Delta t}{\Delta x} \sin(k\Delta x) = |B| e^{-i \frac{U\Delta t}{\Delta x} \tan(k\Delta x)}$$

Logo, a velocidade de fase numérica será

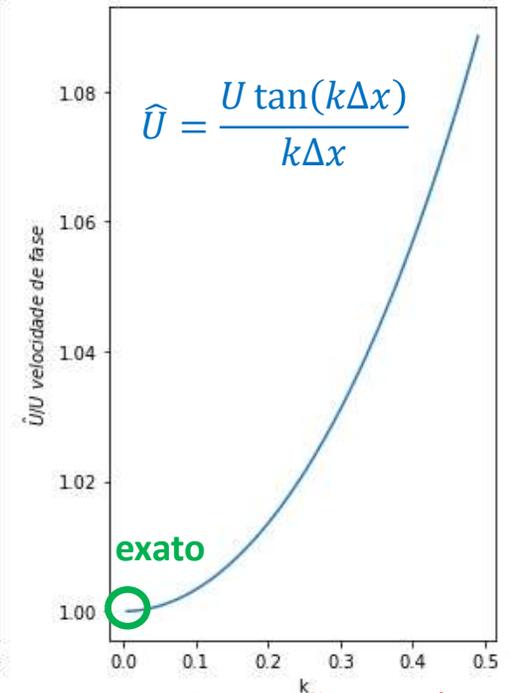
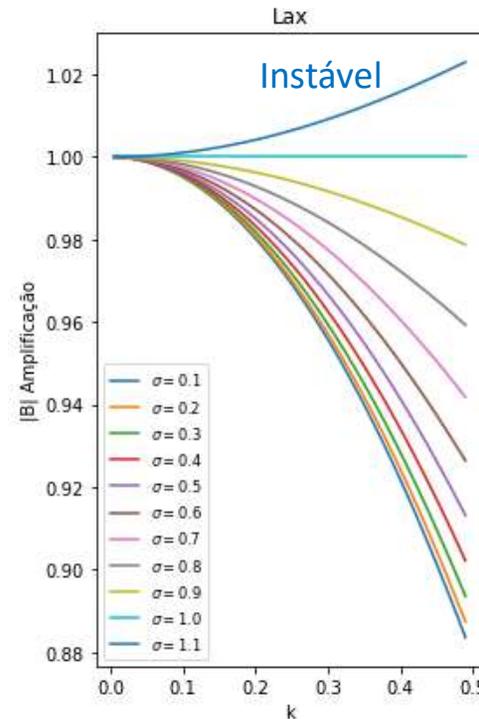
$$\hat{U} = \frac{U \tan(k\Delta x)}{k\Delta x}$$

No $\lim_{k\Delta x \rightarrow 0} \hat{U} = U$: o modelo aproxima-se da solução analítica nos pequenos números de onda k , i.e. nos grandes comprimentos de onda. Fora desse limite a velocidade de fase depende de k e temos **dispersão numérica**.

Comportamento do método de Lax

```

import numpy as np
import matplotlib.pyplot as plt
U=1;dt=1;dx=1;sigma=U*dt/dx
kNyq=1/(2*dx)
Nk=100;
k=np.arange(1,Nk-1)/Nk*kNyq
plt.figure(figsize=(8,6))
for sigma in np.arange(0.1,1.2,0.1):
    Bmod=np.sqrt(np.cos(k*dx)**2+\
        sigma**2*np.sin(k*dx)**2)
    plt.subplot(1,2,1);plt.plot(k,Bmod,\
        label=r'$\sigma=%2.1f$' % sigma)
plt.ylabel('|B| Amplificação');
plt.xlabel('k')
plt.legend(loc='lower left')
plt.title('Lax')
plt.subplot(1,2,2)
Urel=np.tan(k*dx)/(k*dx);plt.plot(k,Urel)
plt.ylabel(r'$\hat{U}/U$');plt.xlabel('k')
plt.tight_layout()
    
```

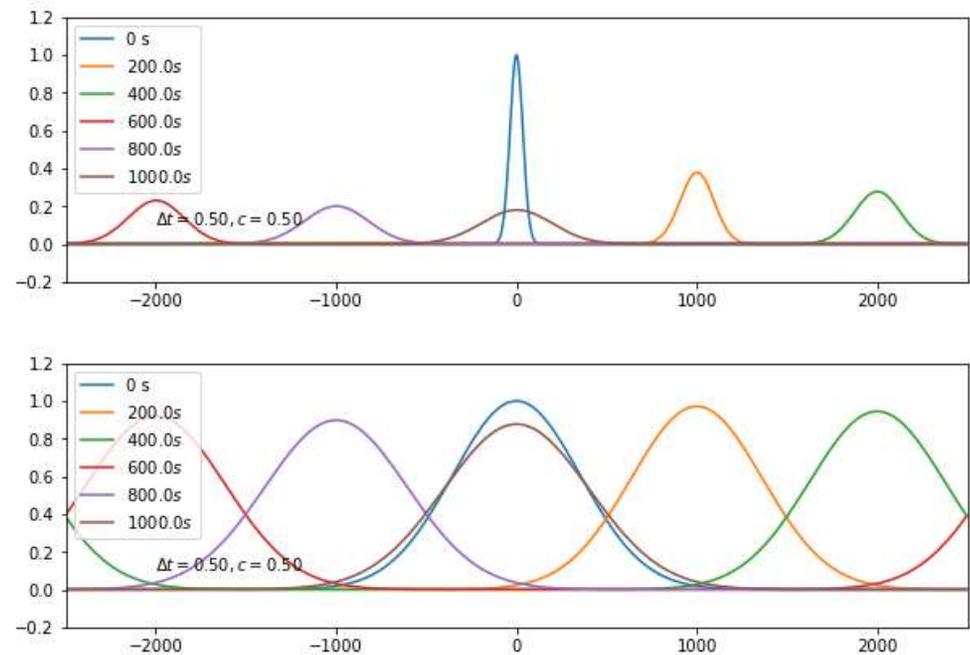


$$|B| = \sqrt{\cos^2(k\Delta x) + \frac{U^2\Delta t^2}{\Delta x^2} \sin^2(k\Delta x)}$$

Advecção linear pelo método de Lax

No método de Lax os pequenos comprimento de onda são rapidamente atenuados, escondendo a dispersão. Os grandes c.d.o. são advectados com a velocidade de fase correta.

Integração de 1 volta ao domínio



Estabilidade do Leapfrog (análise pelo método de von Neumann)

Leapfrog

$$\frac{T_m^{n+1} - T_m^{n-1}}{2\Delta t} = -U \frac{T_{m+1}^n - T_{m-1}^n}{2\Delta x}$$

Substituindo $T_m^n = B^n e^{ikm\Delta x}$:

$$B^{n+1} e^{ikm\Delta x} - B^{n-1} e^{ikm\Delta x} = -\frac{U\Delta t}{\Delta x} (B^n e^{ik(m+1)\Delta x} - B^n e^{ik(m-1)\Delta x})$$

$$B^1 - B^{-1} = -\frac{U\Delta t}{\Delta x} (e^{ik\Delta x} - e^{-ik\Delta x}) = -i \frac{2U\Delta t}{\Delta x} \sin(k\Delta x)$$

Obtemos a equação do 2º grau para B ($\sigma = U\Delta t/\Delta x$):

$$B^2 + 2i\sigma \sin(k\Delta x) B - 1 = 0$$

Aplicação ao Leapfrog (2)

$$B^2 + 2i\sigma \sin(k\Delta x) B - 1 = 0$$

Resolvendo:

$$B = \frac{(-2i\sigma \sin(k\Delta x) \pm \sqrt{-4\sigma^2 \sin^2(k\Delta x) + 4})}{2}$$

$$= -i\sigma \sin(k\Delta x) \pm \sqrt{1 - \sigma^2 \sin^2(k\Delta x)}$$

Se $\sigma \leq 1$ (Nºcourant) o radicando é real e:

$$|B| = \sigma^2 \sin^2(k\Delta x) + 1 - \sigma^2 \sin^2(k\Delta x) = 1$$

E a amplitude é conservada (não há amplificação nem atenuação, $\forall k$).

Aplicação ao Leapfrog (3)

$$B = -i\sigma \sin(k\Delta x) \pm \sqrt{1 - \sigma^2 \sin^2(k\Delta x)}$$

com $\sigma \leq 1$ (radicando é real) $|B_{1,2}| = 1$, logo as duas raízes são:

$$B_1 = e^{-i\theta_k}$$

$$B_2 = -e^{i\theta_k}$$

onde: $\sin \theta_k = \sigma \sin(k\Delta x)$.

A fase tem um comportamento complicado, devido á existência de duas raízes na equação do 2º grau.

A solução geral será uma combinação linear das soluções parcelares, com duas constantes a determinar pelas condições iniciais: (n é o passo de tempo)

$$T_m^n = (CB_1^n + DB_2^n)e^{ikm\Delta x} = \left(Ce^{-in\theta_k} + D(-e^{i\theta_k})^n \right) e^{ikm\Delta x}$$

Atenção aos () !
 n PAR vs n ÍMPAR

Aplicação ao Leapfrog: solução geral

$$\begin{aligned} T_m^n &= (CB_1^n + DB_2^n)e^{ikm\Delta} = \left(Ce^{-in\theta_k} + D(-e^{i\theta_k})^n \right) e^{ikm\Delta x} \\ &= C e^{i(km\Delta x - n\theta_k)} + D(-1)^n e^{i(km\Delta x + n\theta_k)} \end{aligned}$$

Onda progressiva

Onda regressiva, com amplitude a mudar de sinal entre passos de tempo

MODO FÍSICO

MODO Computacional

A solução é estável quando $n \rightarrow \infty$, se $\theta_k \in \mathbb{R}$, i.e. $\sigma \leq 1$ (Número de Courant)

Solução exata seria:

$$T_m^n = e^{ik(m\Delta x - Un\Delta t)}$$

Aplicação ao Leapfrog: condições iniciais

$$T_m^n = (CB_1^n + DB_2^n)e^{ikm\Delta} = \left(Ce^{-in\theta_k} + D(-e^{i\theta_k})^n \right) e^{ikm\Delta x}$$

Condição inicial:

$$T(x = m\Delta x, t = 0) \approx T_m^0 = e^{ikm\Delta x} \Rightarrow (C + D) = 1$$

Falta uma condição que terá de ser determinada pelo método usado na primeira iteração, visto que o leapfrog só pode ser usado na segunda... Se a primeira iteração usar o método de Euler:

$$\frac{T_m^{n+1} - T_m^n}{\Delta t} = -U \frac{T_{m+1}^n - T_{m-1}^n}{2\Delta x} \Rightarrow T_m^1 = T_m^0 - \frac{U\Delta t}{2\Delta x} (T_{m+1}^0 - T_{m-1}^0)$$

$$(CB_1 + DB_2)e^{ikm\Delta} = e^{ikm\Delta x} - \frac{U\Delta t}{2\Delta x} (e^{ik(m+1)\Delta x} - e^{-ik(m-1)\Delta x})$$

Aplicação ao Leapfrog (6)

$$(C + D) = 1,$$

$$(Ce^{-i\theta_k} - De^{i\theta_k})e^{ikm\Delta x} = e^{ikm\Delta x} - \frac{U\Delta t}{2\Delta x} (e^{ik(m+1)\Delta x} - e^{ik(m-1)\Delta x})$$

$$(Ce^{-i\theta_k} - De^{i\theta_k}) = 1 - \frac{U\Delta t}{2\Delta x} (e^{ik\Delta x} - e^{-ik\Delta x}) = 1 - i \sin \theta_k$$

Logo:

$$(Ce^{-i\theta_k} - (1 - C)e^{i\theta_k}) = 1 - i \sin \theta_k$$

$$C(e^{-i\theta_k} + e^{i\theta_k}) - e^{i\theta_k} = 1 - i \sin \theta_k$$

$$2C \cos \theta_k = \cos \theta_k + i \sin \theta_k + 1 - i \sin \theta_k$$

$$C = \frac{1 + \cos \theta_k}{2 \cos \theta_k}$$

Leapfrog: Solução completa

$$T_m^n = \frac{1 + \cos \theta_k}{2 \cos \theta_k} e^{i(km\Delta x - n\theta_k)} - \frac{1 - \cos \theta_k}{2 \cos \theta_k} (-1)^n e^{i(km\Delta x + n\theta_k)}$$

Com $\theta_k = \sin^{-1}(\sigma \sin(k\Delta x))$, $\sigma = \frac{U\Delta t}{\Delta x} \leq 1$ (condição CFL)

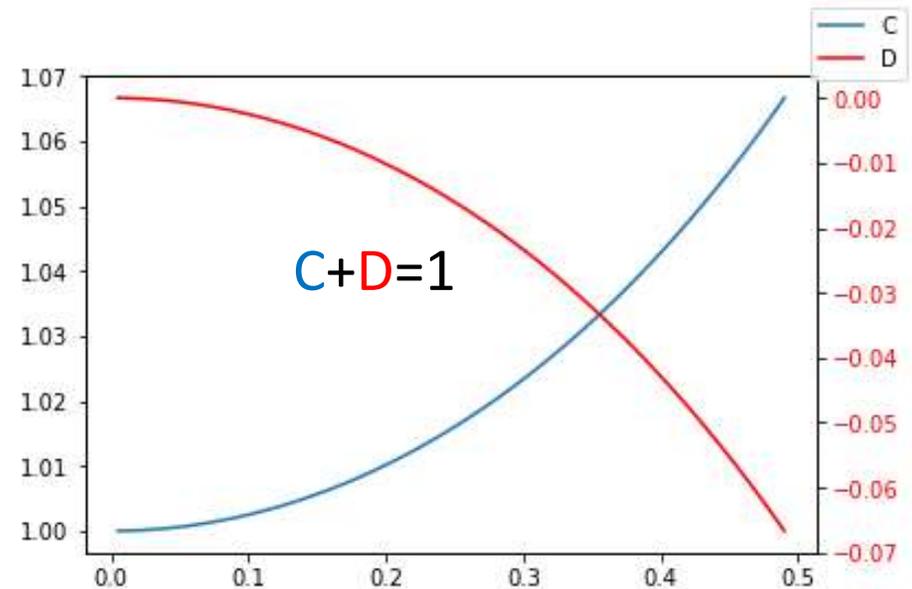
Se $\sigma = 1$, $\theta_k = k\Delta x = kU\Delta t$, e o **modo físico** propaga-se à velocidade da solução exata, e o **modo numérico** propaga-se à mesma velocidade mas na direção oposta. A amplitude relativa dos dois modos depende do número de onda.

Os pequenos k (grandes λ) são melhor representados.

O método é **dispersivo**: a velocidade de fase (que devia ser constante) depende de k .

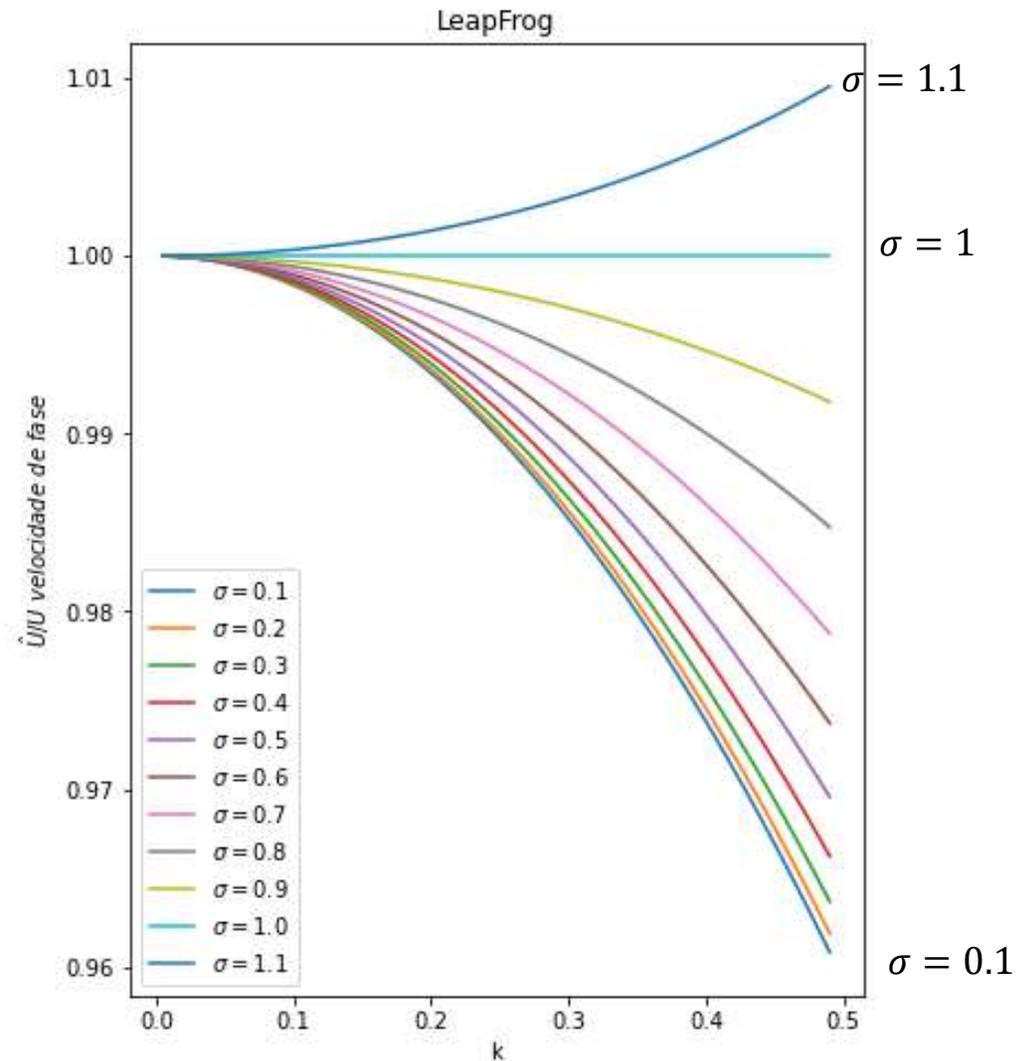
Cálculo de C,D

```
fig,ax1=plt.subplots()  
U=1;dt=1;dx=1;sigma=U*dt/dx  
kNyq=1/(2*dx)  
Nk=100  
k=np.arange(1,Nk-1)/Nk*kNyq  
thetak=np.arcsin(sigma*np.sin(k*dx));  
C=(1+np.cos(thetak))/(2*np.cos(thetak));  
D=1-C  
ax1.plot(k,C,label='C')  
ax2=ax1.twinx()  
ax2.plot(k,D,label='D',color='red')  
ax2.set_xlabel('k')  
  
ax2.tick_params(axis='y',labelcolor='red')  
fig.legend()
```



Velocidade de fase (\hat{U}/U)

```
plt.figure(figsize=(6,8))
for sigma in np.arange(0.1,1.2,0.1):
    dt=sigma*dx/U;
    thetak=np.arcsin(sigma*np.sin(k*dx));
    Uhat=thetak/(k*dt);
    plt.plot(k,Uhat,label=\
        r'\sigma=%2.1f$' % sigma)
plt.ylabel(r'\hat{U}/U\ velocidade\ de\
fase$');plt.xlabel('k')
plt.title('LeapFrog')
plt.legend()
```



Comentário final: leapfrog

A existência dos 2 “modos” resulta do desacoplamento entre as malhas pares/ímpares: os pontos vermelhos e azuis não interagem (excepto talvez na fronteira): essa a razão da necessidade do filtro temporal de Robert-Aselin.

