

Modelação Numérica 2017

Aula 23, 17/Maio

- Estimativa de parâmetros e optimização.
- Solução de problemas lineares sub- e sobre-determinados.

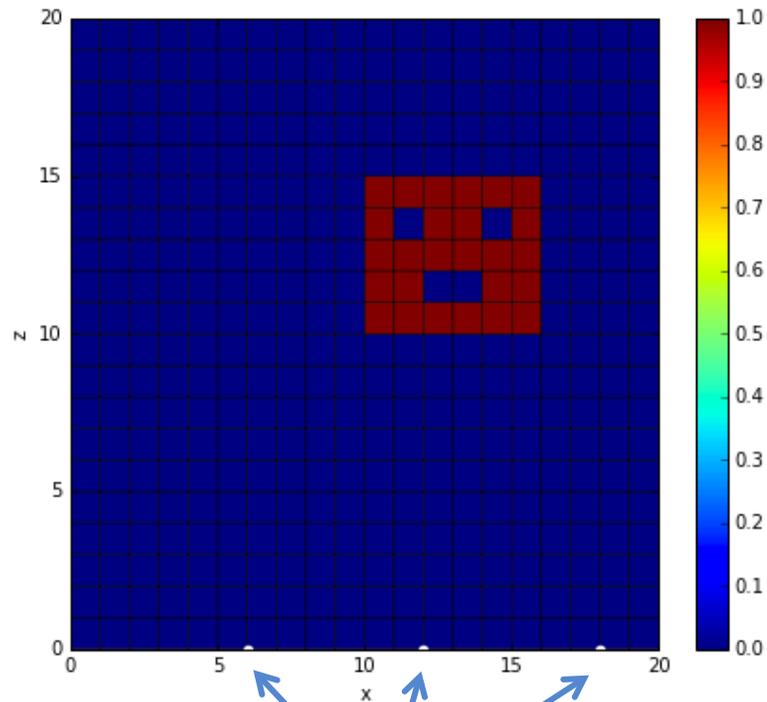
<http://modnum.ucs.ciencias.ulisboa.pt>

Outro exemplo:

Recuperar a forma de um objecto (nuvem, massa enterrada, ...)

Objecto a caracterizar:

$n_x * n_z = 441$ parâmetros (0 ou 1)

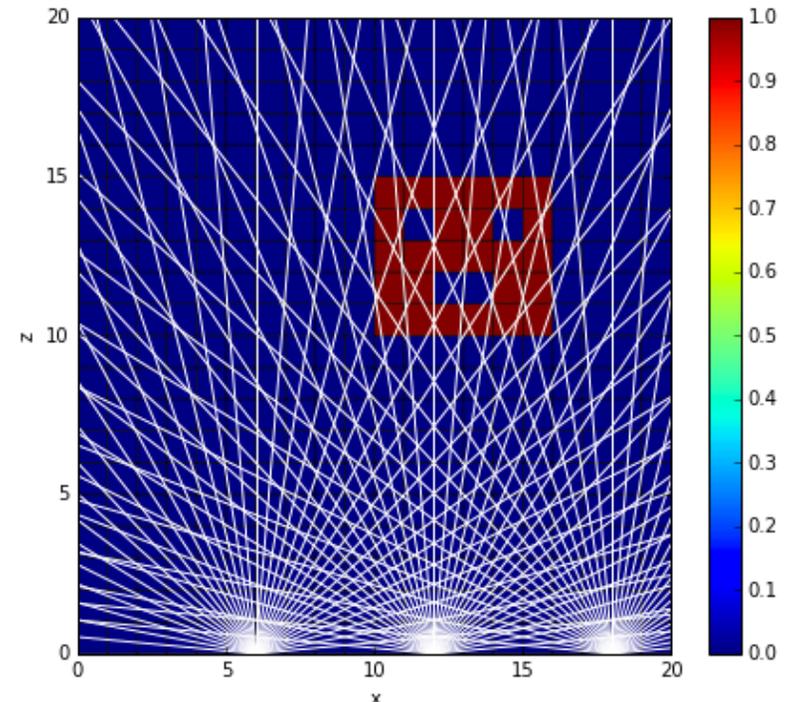


3 estações

Observações:

3 estações * 35 ângulos

= 105 observações (0 ou 1)



Cada sensor vê/mede em cada ângulo o integral ao longo do percurso.

Outro exemplo:

Recuperar a forma de um objecto (nuvem, massa enterrada, ...)

Objecto a caracterizar:

$n_x * n_z = 441$ parâmetros (0 ou 1)

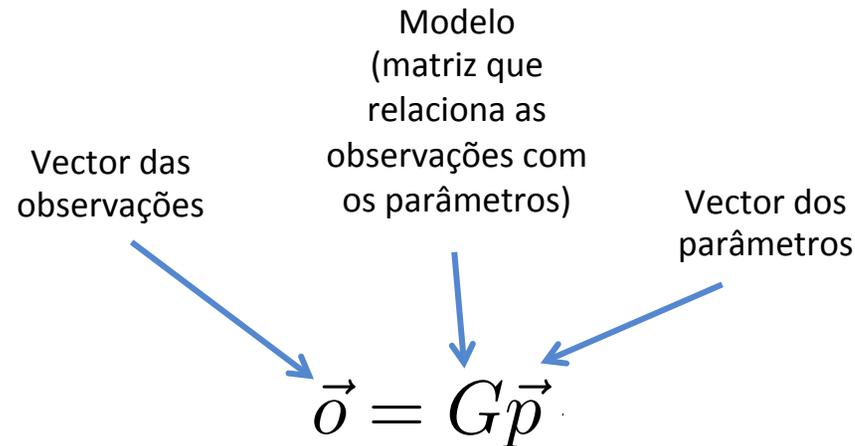
$m=441$

Observações:

3 estações*35 ângulos

= 105 observações (0 ou 1)

$n=105$



$$\begin{bmatrix} o_1 \\ o_2 \\ \dots \\ o_n \end{bmatrix} = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1m} \\ G_{21} & G_{22} & \dots & G_{2m} \\ G_{\dots 1} & G_{\dots 2} & \dots & G_{\dots m} \\ G_{n1} & G_{n2} & \dots & G_{nm} \end{bmatrix} \begin{bmatrix} p_1 & p_2 & p \dots & p_m \end{bmatrix}$$

Outro exemplo:

Recuperar a forma de um objecto (nuvem, massa enterrada, ...)

Objecto a caracterizar:

$n_x * n_z = 441$ parâmetros (0 ou 1)

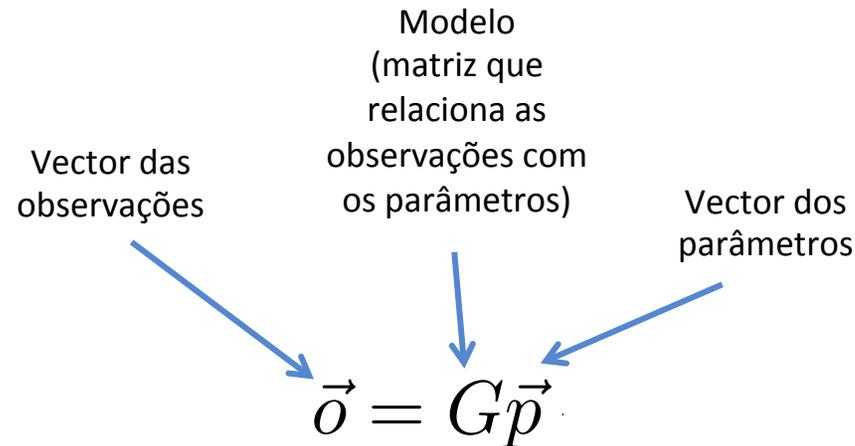
$m=441$

Observações:

3 estações*35 ângulos

= 105 observações (0 ou 1)

$n=105$



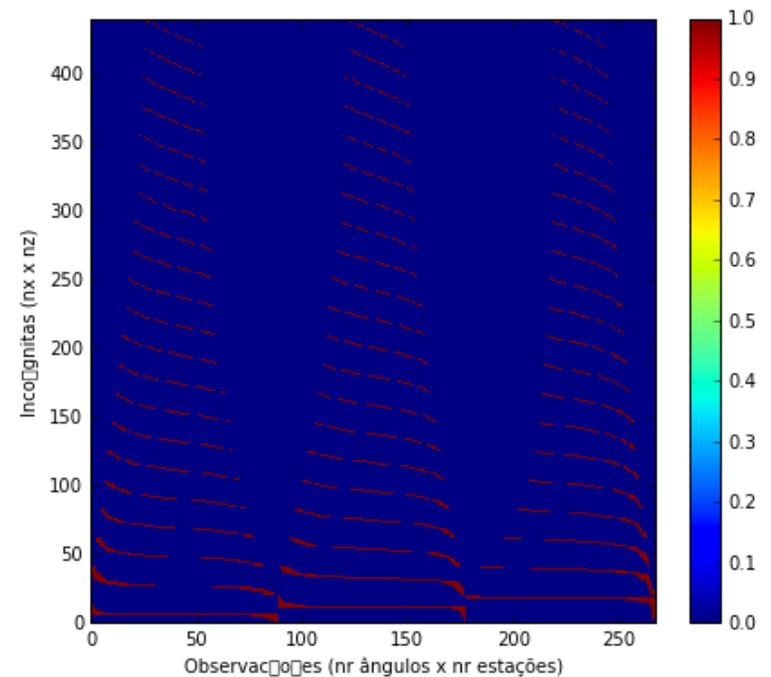
Cada elemento de G descreve o efeito de cada parâmetro em cada observação.

$$\begin{bmatrix} o_1 \\ o_2 \\ \dots \\ o_n \end{bmatrix} = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1m} \\ G_{21} & G_{22} & \dots & G_{2m} \\ G_{\dots 1} & G_{\dots 2} & \dots & G_{\dots m} \\ G_{n1} & G_{n2} & \dots & G_{nm} \end{bmatrix} \begin{bmatrix} p_1 & p_2 & p \dots & p_m \end{bmatrix}$$

Outro exemplo:

Recuperar a forma de um objecto (nuvem, massa enterrada, ...)

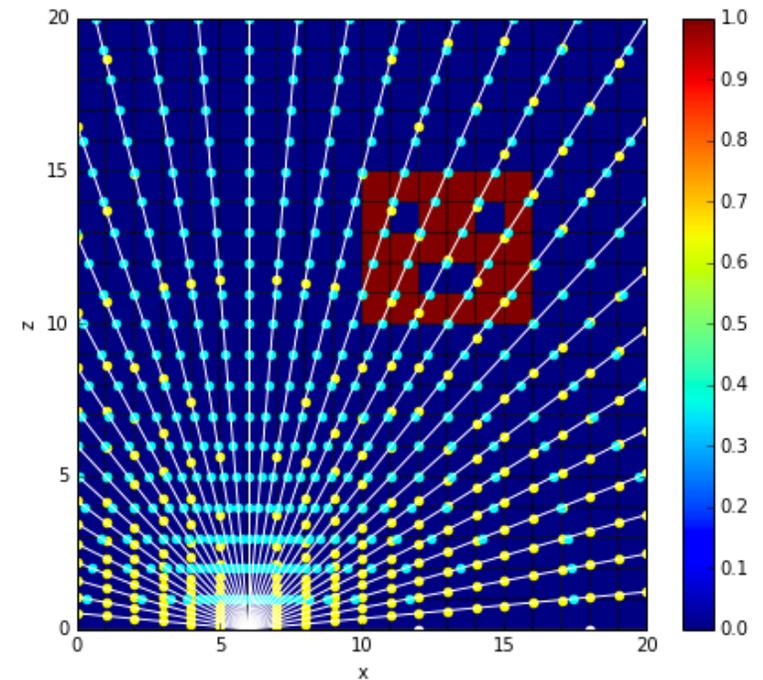
- $m = 441$ parâmetros
- $n = 105$ observações
- Cada linha de G tem 441 membros (tantos quantos os pixels a calcular 21×21)
 - Foi preciso “vetorizar” (reshape) a matriz de parâmetros.
- Cada coluna de G tem 105 membros (3×35):
 - Por vetorização das observações.
- A matriz G depende da geometria (número de sensores, ângulos) e da física do problema (relação entre os valores no espaço físico e as observações remotas): é o modelo.
- A matriz G não depende das observações nem da solução.



$$\begin{bmatrix} o_1 \\ o_2 \\ \dots \\ o_n \end{bmatrix} = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1m} \\ G_{21} & G_{22} & \dots & G_{2m} \\ \dots & \dots & \dots & \dots \\ G_{n1} & G_{n2} & \dots & G_{nm} \end{bmatrix} \begin{bmatrix} p_1 & p_2 & p_{\dots} & p_m \end{bmatrix}$$

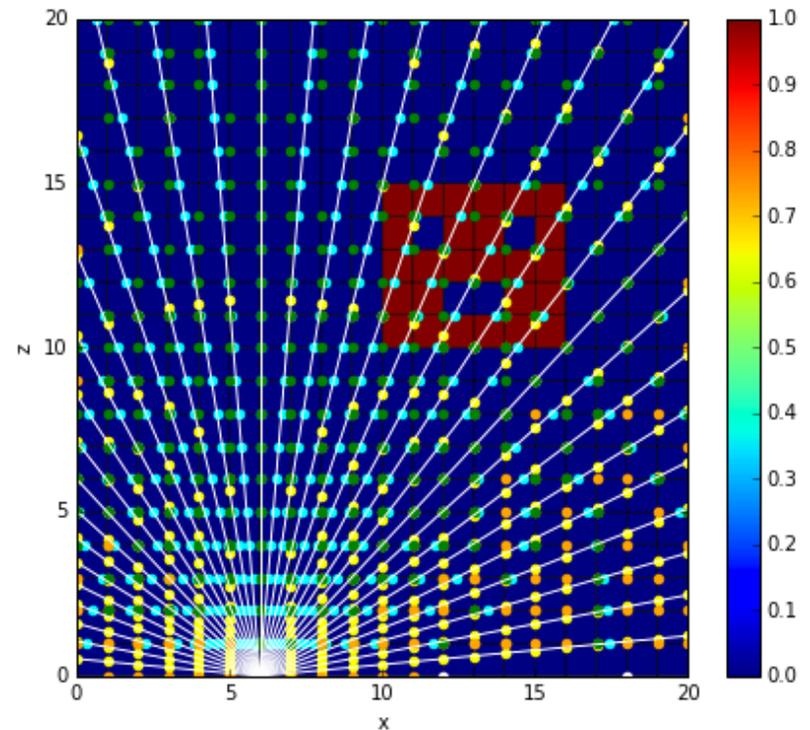
Determinação da matriz G

- Inicializar a matriz a 0.
- Cada elemento da matriz G é
 - (1 observação vs 1 pixel)
 - Ou seja: (1 sensor + 1 ângulo vs 1 n_x + 1 n_y)
- Para cada sensor: Para cada ângulo localizar os pixels atravessados e marcá-los a 1.



Determinação da matriz G

- Inicializar a matriz a 0.
- Cada elemento da matriz G é
 - (1 observação vs 1 pixel)
 - Ou seja: (1 sensor + 1 ângulo vs 1 n_x + 1 n_y)
- Para cada sensor: Para cada ângulo localizar os pixels atravessados e marcá-los a 1.
- Aproximar na grelha regular.



```
import matplotlib.pyplot as plt
import numpy as np

from math import pi as pi
from numpy.linalg import pinv as pinv

#%%
plt.rcParams['figure.figsize'] = 10, 6

##### Inicialização

### número de pontos
nx=21
nz=21

### espaçamento entre pontos
dx=1.
dz=1.

### vectores x e z
x=np.arange(nx)*dx
z=np.arange(nz)*dz

### limited do domínio
xmin=np.min(x)
xmax=np.max(x)
zmin=np.min(z)
zmax=np.max(z)

### matrizes 2D em x e y
xx=np.zeros([nx,nz])
zz=np.zeros([nx,nz])

for ix in range(nx):
    for iz in range(nz):
        xx[ix,iz]=x[ix]
        zz[ix,iz]=z[iz];
```

```

### matrizes 2D com a solução a descobrir
SS=np.zeros([nx,nz])
for ix in range(10,16):
    for iy in range(10,15):
        SS[ix,iy]=1

SS[11,13]=0
SS[14,13]=0
SS[12:14,11]=0

#%
### plot
plt.close()
plt.rcParams['figure.figsize'] = 7,6

plt.pcolor(xx,zz,SS, edgecolors='k', linewidths=.5)
plt.colorbar()
plt.xlabel('x')
plt.ylabel('z');
plt.xlim([xmin, xmax])
plt.ylim([zmin, zmax])
#%
### Observações

### Pontos de observação (estações)
xE=np.array([6,12,18])*dx
zE=np.zeros(len(xE))

plt.scatter(xE,zE, color='white')
#%

```

```

### ...
#da=5.
da=2.
#da=1.
#da=.5
angE=np.arange(da,180,da)      # ângulos
slopeE=np.tan(angE*pi/180.)    # declive

nEx=len(xE)                    # nr de estações
nEa=len(angE)                  # nr de ângulos
nobs=nEx*nEa                   # nr total de observações
npar=nx*nz                      # nr de parâmetros a encontrar/optimizar

## construção da matriz G
G=np.zeros([nobs,npar])        # matriz do modelo (ex: funções de Green)

zintx=np.zeros(nx)
zintz=np.zeros(nz)
xintz=np.zeros(nz)
xintx=np.zeros(nx)

```

```

iObs=0;
for iEs in range(nEx):           # para cada estação
    for iEa in range(nEa):      # para cada ângulo
        xis=xE[iEs]            # x da estação
        slope=slopeE[iEa]      # declive correspondente ao ângulo (observação)

        for ix in range(nx):    # para cada ponto em x
            zintx[ix] = zE[iEs] + slope*(x[ix]-xis)
            xintx[ix] = x[ix];

        for iz in range(nz):    # para cada ponto em z
            zintz[iz] = z[iz]
            xintz[iz] = xis + (z[iz]-zE[iEs])/slope

        plt.plot(xintx,zintx, color='white')      # linhas
#         plt.scatter(xintx,zintx, color='yellow') # pontos a x constante
#         plt.scatter(xintz,zintz, color='cyan')   # pontos a z constante

        for ix in range(nx):
            if zintx[ix]>=zmin and zintx[ix]<=zmax:
                iZ=np.round(zintx[ix]/dz)
                iPar=(iZ)*nx+ix
                G[iObs,int(iPar)]=1
#                 plt.scatter(x[ix],z[iZ], color='orange') # pontos a z constante

        for iz in range(nz):
            if xintz[iz]>=xmin and xintz[iz]<=xmax:
                ix=np.round(xintz[iz]/dx)
                iPar=(iz)*nx+ix
                G[iObs,(iPar)]=1
#                 plt.scatter(x[ix],z[iz], color='green') # pontos a z constante

iObs=iObs+1;

```

```

# %% plot matriz G
plt.close()
plt.rcParams['figure.figsize'] = 7,6

plt.pcolor(np.transpose(G))
plt.colorbar()
plt.xlabel(u'Observações (nr ângulos x nr estações)')
plt.ylabel(u'Incógnitas (nx x nz)')
plt.xlim([0,nobs])
plt.ylim([0,npar])

# %% Observações sintéticas

S=np.reshape(SS, [nx*nz,1])          # solução vectorizada
obs=np.dot(G,S)                      # observações vectorizadas (na forma de um vector 1D)

## solução

Xest=np.dot(pinv(G),obs)             # solução
Xmat=np.reshape(Xest, [nx,nz])

plt.close()
plt.rcParams['figure.figsize'] = 7,6

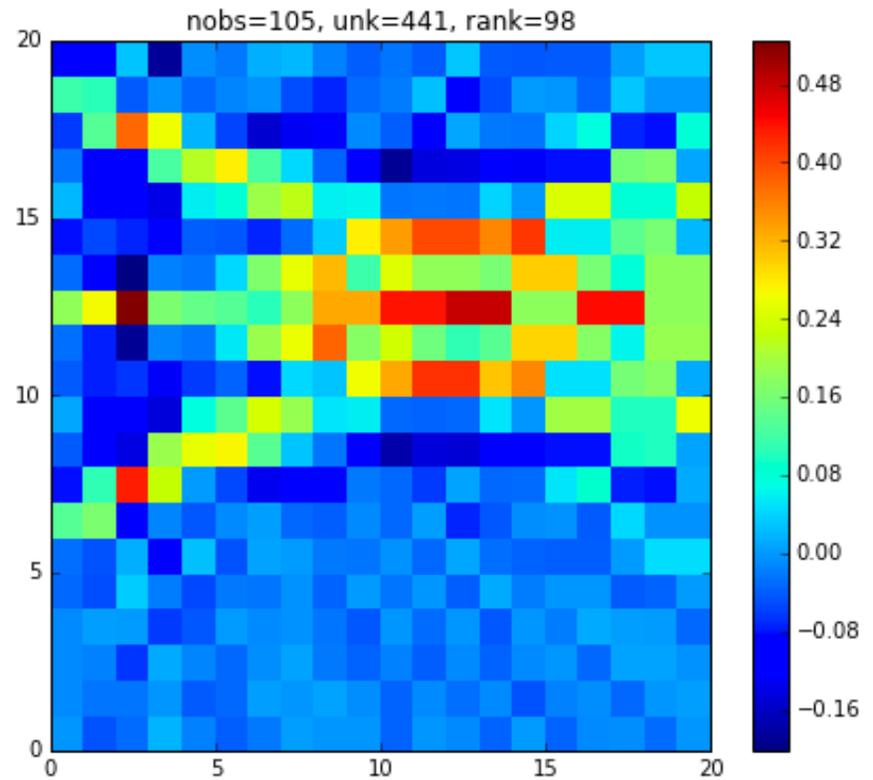
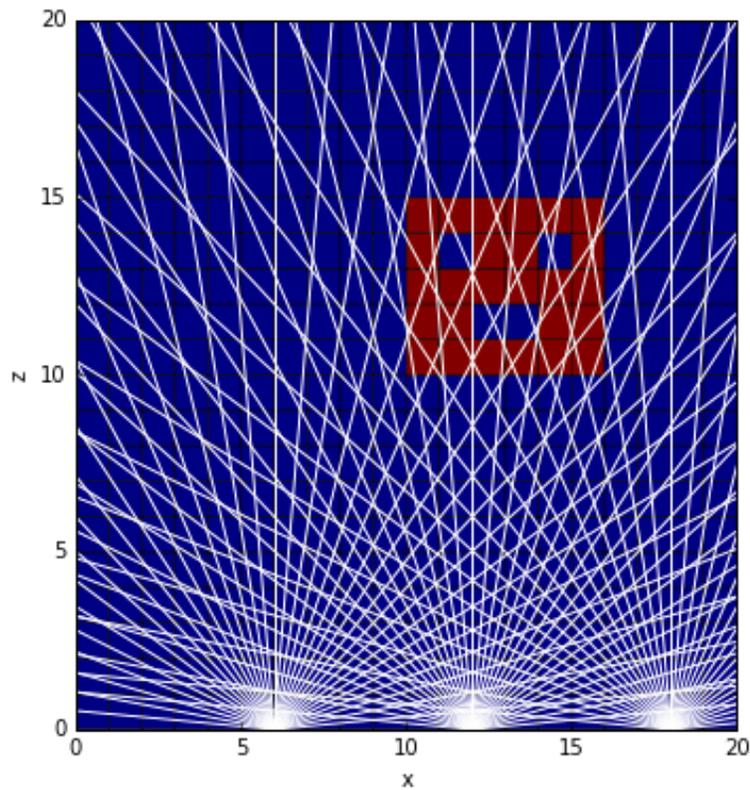
plt.pcolor(xx,zz,Xmat)
plt.colorbar()
rank=np.linalg.matrix_rank(G)
plt.title('nobs='+str(nobs)+' , unk='+str(npar)+' , rank='+str(rank))

```

Solução (nobs=105)

Notar que $\text{rank}(A)=98 < 105$, logo há observações redundantes.

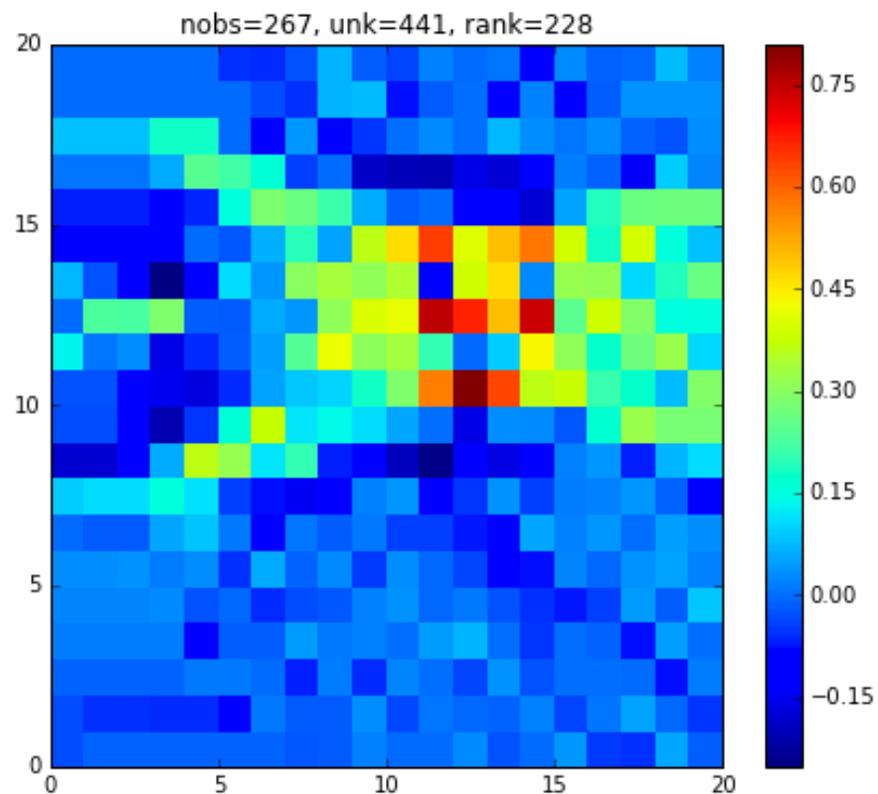
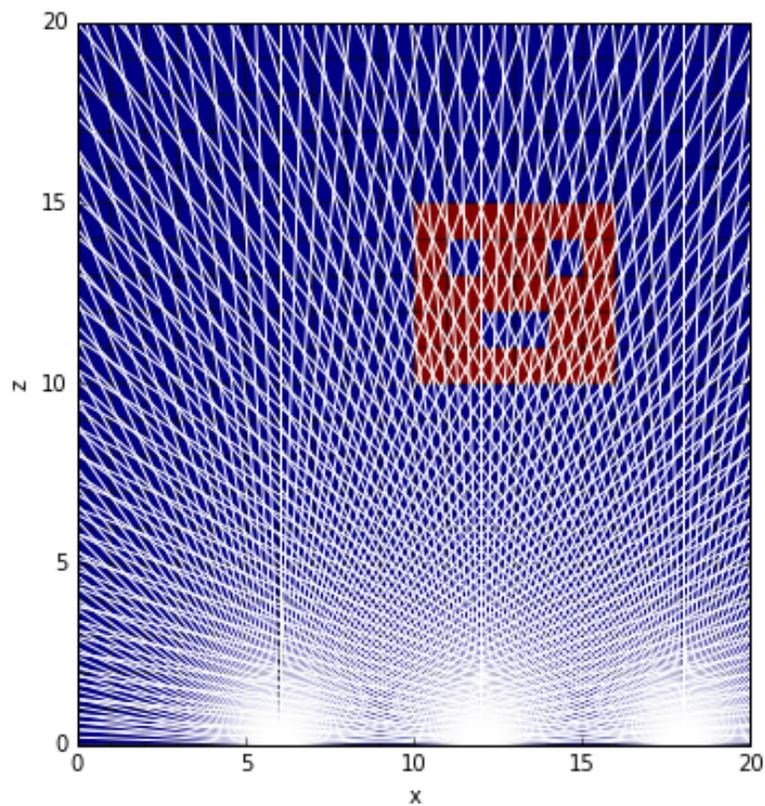
O problema é subdeterminado...



Solução (nobs=267)

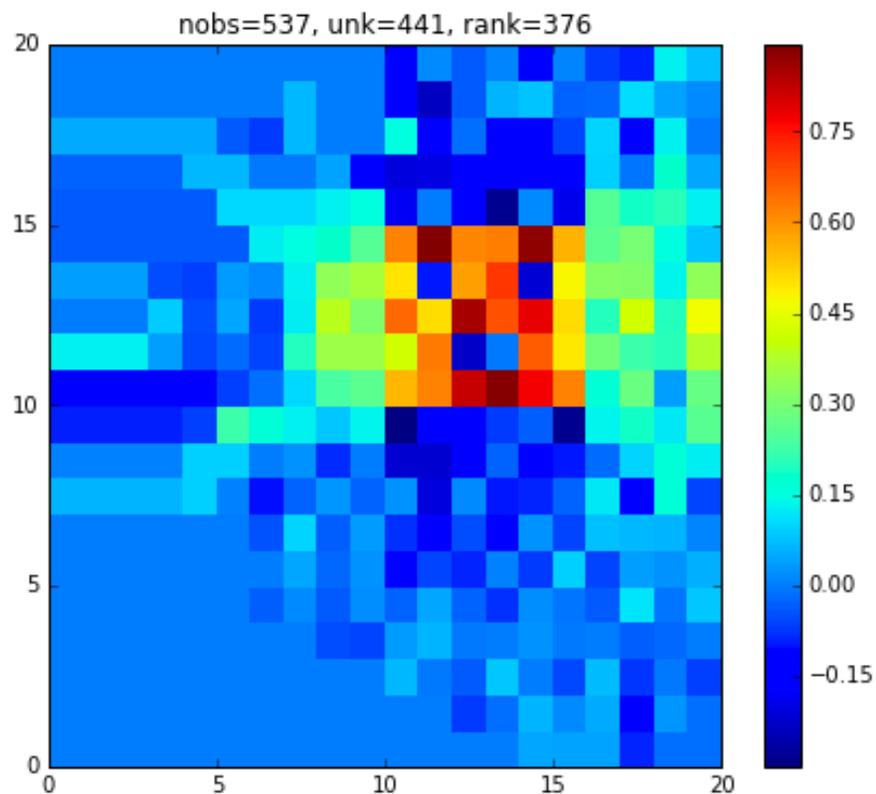
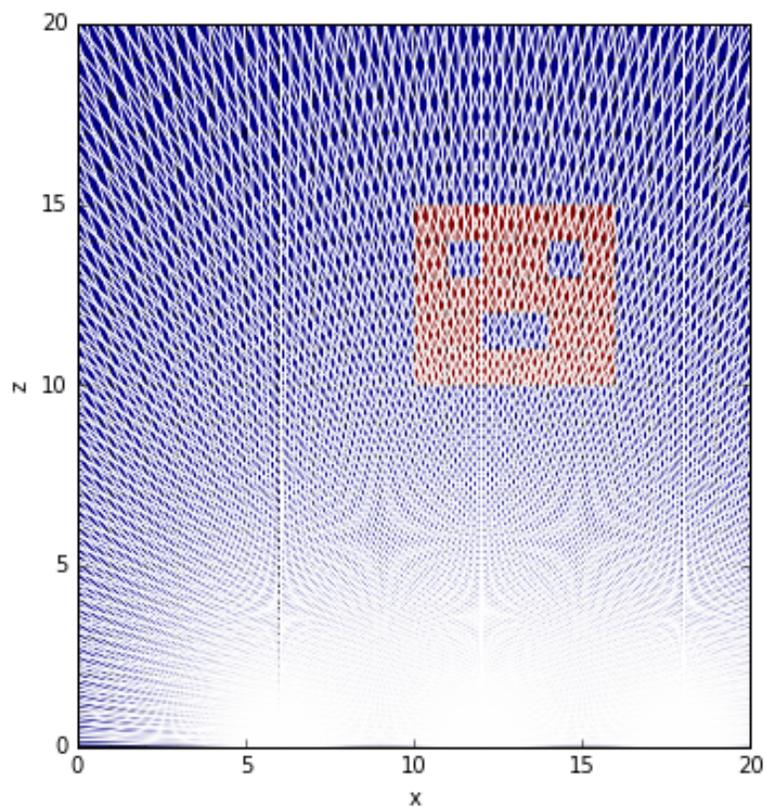
Notar que $\text{rank}(A)=228 < 267$, logo há observações redundantes.

O problema é subdeterminado...



Solução (nobs=537)

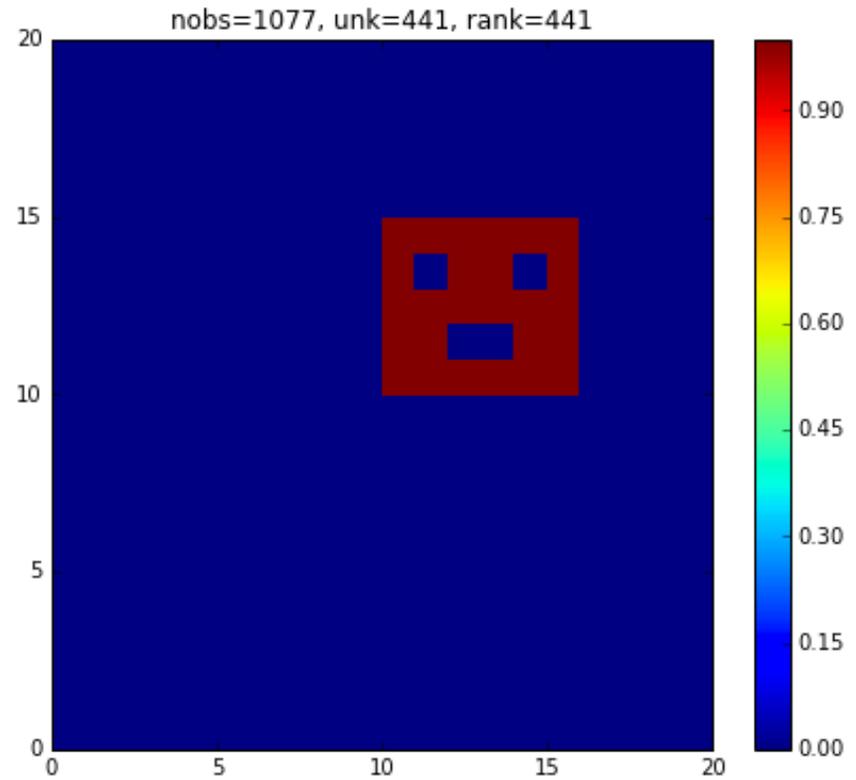
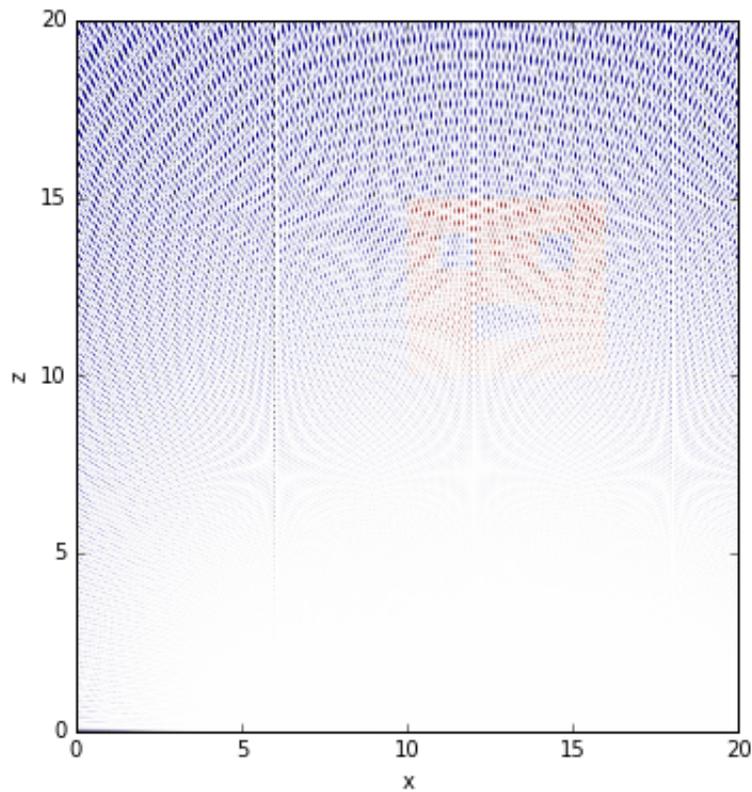
Notar que $\text{rank}(A)=376 < 537$, logo há observações redundantes.



Solução (nobs=1077)

Notar que $\text{rank}(A)=441$.

Perfeito!



Comentários

- O problema resolve-se facilmente, mas [a matriz do modelo dá trabalho a construir...](#) O algoritmo funciona também para problemas que não sejam sub-determinados (mas é mais caro que o necessário, mas mais robusto).
- Optou-se por uma matriz de 0 e 1. Seria mais preciso calcular em cada pixel atravessado [o percurso do raio através do pixel](#). Dava mais trabalho mas seria essencial para poder reconstituir objetos de “densidade” variável.
- Em problemas 3D a subdeterminação é frequentemente avassaladora. Só é possível obter uma solução iterativamente a partir de uma solução inicial (first guess) já próxima da solução procurada. O processo descrito seria aplicado em cada iteração para a correção a introduzir à solução.