
TP 1

Pour commencer, connectez-vous au serveur L3 <https://jupyterl3.mecanique.univ-lyon1.fr/> avec vos identifiant et mot de passe de l'université.

Cliquez sur Start pour ouvrir un notebook.

Ensuite, récupérer le notebook du TP 1 en procédant comme suit :

1. Choisir *Assignments*.
2. Dans le menu *Released, downloaded, and submitted assignments for course*, choisir MAT3146L.
3. Puis *Fetch* TP1_16_novembre dans la rubrique *Released assignments*.
4. Cliquer sur le lien TP1_16_novembre se trouvant à gauche dans la rubrique *Downloaded assignments*, puis juste en-dessous sur le lien vers le notebook `tp_1`.

On charge les modules `numpy`, `numpy.linalg`, `matplotlib` et `scipy.stats` qui seront utilisés dans le TP.

```
[ ]: import numpy as np
import numpy.linalg as npl
import matplotlib.pyplot as plt
import scipy.stats
%matplotlib notebook
```

1 Exercice 1 : Décomposition en valeurs singulières

1.1 Première partie : énoncé.

Soit $A \in \mathcal{M}_n(\mathbb{R})$ inversible, avec $n \in \mathbb{N}^*$. En utilisant la décomposition en valeurs singulières de A , $A = V\Sigma U^t$ où U et V sont unitaires, et Σ est diagonale, nous allons montrer que l'image de la boule unité par A est une ellipse de centre 0, dont on sait déterminer les axes.

Nous commençons par montrer qu'une telle décomposition de A existe.

Dans la suite, les vecteurs de \mathbb{R}^n sont identifiés à des vecteurs colonnes et $\|\cdot\|$ désigne la norme euclidienne canonique.

1.1.1 1) Existence de la décomposition

a) Montrer que $A^t A$ est symétrique et définie positive. En déduire qu'il existe des réels strictement positifs μ_1, \dots, μ_n et une base orthonormée (u_1, \dots, u_n) tels que pour tout $k = 1, \dots, n$, $A^t A u_k = \mu_k^2 u_k$.

On dit que μ_1, \dots, μ_n sont les valeurs singulières de A .

```
[ ]: #
#
#
#
```

```
#  
#
```

b) Pour tout $k = 1, \dots, n$, on pose $v_k = \frac{1}{\mu_k} Au_k$. Montrer que (v_1, \dots, v_n) est une base orthonormée de \mathbb{R}^n , constituée de vecteurs propres de AA^t .

```
[ ]: #  
#  
#  
#  
#  
#  
#  
#  
#  
#  
#  
#  
#
```

c) On note U la matrice dont les vecteurs colonnes sont (u_1, \dots, u_n) et V la matrice dont les vecteurs colonnes sont (v_1, \dots, v_n) . On note $\Sigma = \text{diag}(\mu_1, \dots, \mu_n)$. Montrer que $A = V\Sigma U^t$.

```
[ ]: #  
#  
#  
#  
#  
#  
#  
#  
#  
#  
#
```

1.1.2 2) Image de la sphère unité par A

a) Montrer que l'image de la sphère unité $S = \{x \in \mathbb{R}^n \text{ t.q. } \|x\| = 1\}$ par la matrice unitaire U^t est S .

```
[ ]: #  
#  
#  
#  
#
```

b) Montrer que l'image de la sphère unité par la matrice diagonale Σ est l'ellipse

$$E_1 = \left\{ x \in \mathbb{R}^n \text{ t.q. } \sum_{k=1}^n \left(\frac{x_k}{\mu_k} \right)^2 = 1 \right\}.$$

E_1 est l'ellipse dont les axes sont ceux du repère canonique et les demi-longueurs sont les $(\mu_k)_{1 \leq k \leq n}$.

[]: #

#

c) Montrer que l'image par la matrice orthogonale V de l'ellipse E_1 est l'ellipse

$$E_2 = \left\{ x \in \mathbb{R}^n \text{ t.q. } \sum_{k=1}^n \left(\frac{(V^t x)_k}{\mu_k} \right)^2 = 1 \right\}.$$

E_2 est l'ellipse dont les axes sont les vecteurs colonnes de V et les demi-longueurs sont les $(\mu_k)_{1 \leq k \leq n}$.

[]: #

#

d) En déduire que l'image par A de la sphère unité S est l'ellipse, notée E_A , dont les axes sont les vecteurs colonnes v_k de V et les demi-longueurs respectives les μ_k .

[]: #

#

e) En déduire que l'image par la matrice A de la boule unité est l'ellipse « pleine »

$$\left\{ x \in \mathbb{R}^n \text{ t.q. } \sum_{k=1}^n \left(\frac{(V^t x)_k}{\mu_k} \right)^2 \leq 1 \right\}.$$

[]: #

#

```
#  
#  
#
```

1.2 Seconde partie : visualisation.

Le but de la suite cet exercice est de *visualiser* le fait que l'image de la boule unité par une matrice réelle carrée A est un ellipsoïde dont les axes sont les vecteurs propres de AA^t et dont les demi-longueurs sont les valeurs singulières de A . Pour visualiser ceci on choisit la dimension 2.

1.2.1 1)

Définir la matrice

$$A = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}.$$

```
[ ]: A = np.array([[1, 1],[0,1]])  
print(A)
```

1.2.2 2)

Choisir 1000 points aléatoirement selon la loi uniforme dans $B(0,1)$ et les représenter.

On admet qu'une solution pour définir un tel ensemble de points est de chercher des points aléatoirement selon la loi uniforme dans le carré $[-1,1]^2$ et de ne sélectionner que ceux qui sont dans la boule.

```
[ ]: N = 1000  
n = 1  
Y = np.empty((N,2))  
while n < N:  
    X = 2.*np.random.rand(1,2) - 1  
    if np.linalg.norm(X) <= 1:  
        Y[n,:] = X  
        n = n + 1  
plt.plot(Y[:,0],Y[:,1],".")  
plt.axis('equal')  
plt.grid()  
plt.show()
```

1.2.3 3)

Calculer l'image de ces 1000 points par l'application dont la matrice est A et les tracer sur le même dessin.

```
[ ]: Z = np.empty((N,2))  
for n in range(N):  
    Z[n,:] = # à compléter  
plt.plot(Z[:,0],Z[:,1],".")  
plt.axis('equal')  
plt.grid()  
plt.show()
```

1.2.4 4)

À l'aide de la fonction `np.linalg.eig` calculer les (valeurs approchées des) valeurs propres λ_1 et λ_2 et vecteurs propres associés respectivement u_1 et u_2 de $A^t A$ puis calculer Au_1 et Au_2 . On peut aussi faire le calcul exact à la main !

```
[ ]: AtA = np.dot(np.transpose(A),A)
      valpro, vecpro = np.linalg.eig(AtA)
      l1 = valpro[0]
      u1 = vecpro[:,0]
      l2 = valpro[1]
      u2 = vecpro[:,1]
      Au1 = # à compléter
      Au2 = # à compléter
      vs1 = np.sqrt(l1)
      vs2 = np.sqrt(l2)

      print(Au1)
      print(Au2)
      print(np.dot(u1,u2))
```

1.2.5 5)

Représenter sur le même dessin les segments ayant une extrémité $0 \in \mathbb{R}^2$, alignés avec Au_1 et Au_2 (ils sont de longueurs $\sqrt{\lambda_1}$ et $\sqrt{\lambda_2}$).

```
[ ]: plt.plot([0.,Au1[0]],[0.,Au1[1]],'b')
      plt.plot([0.,Au2[0]],[0.,Au2[1]],'b')
      plt.grid()
      plt.show()
```

2 Exercice 2 : conditionnement et stabilité des solutions de systèmes linéaires

On s'intéresse à la solution du problème $Ax = b$ où

$$A = \begin{pmatrix} 1 & 0.1 & 0.01 & 0.001 & 0.0001 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1.5 & 2.25 & 3.375 & 5.0625 \\ 1 & 2 & 4 & 8 & 16 \\ 1 & 3 & 9 & 27 & 81 \end{pmatrix} \quad \text{et} \quad b = \begin{pmatrix} 0.01 \\ 1 \\ 2.25 \\ 4 \\ 9 \end{pmatrix}.$$

2.1 1)

Le module `numpy` de python a une fonction de résolution de systèmes linéaires : la commande `np.linalg.solve(A,b)` renvoie le résultat x du système ci-dessus. Quel est le résultat obtenu ? Aurait-on pu le trouver sans calcul ?

```
[ ]: A = np.array([[1,0.1,0.01,0.001,0.0001],[1,1,1,1,1],[1,1.5,2.25,3.375,5.
↪0625],[1,2,4,8,16],[1,3,9,27,81]])
b = np.array([0.01,1,2.25,4,9])
print(A)
print(b)
print(npl.solve(A,b))
```

2.2 2)

Rappeler la définition de $cond_2(A)$ et en donner une valeur approchée en utilisant la commande `npl.cond`.

```
[ ]: #
#
```

```
[ ]: print(npl.cond(A,2))
```

2.3 3)

À l'aide de la commande `10**-3*np.random.rand(np.shape(A)[0],np.shape(A)[1])`, définir une matrice $B = A + \delta A$ où δA est définie de manière « aléatoire ». Résoudre $By = b$ et évaluer la quantité

$$\frac{\|y - x\|_2}{\|y\|_2} \frac{\|A\|_2}{\|\delta A\|_2}$$

en utilisant la commande `npl.norm`. Faire ceci pour différentes perturbations δA .

```
[ ]: dA = 10**-3*np.random.rand(np.shape(A)[0],np.shape(A)[1])
B = A + dA
x = # à compléter
y = # à compléter
rapportdA = npl.norm(y - x)/npl.norm(y)*npl.norm(A,2)/npl.norm(dA,2)
# Attention : par défaut pour un vecteur npl.norm renvoie la norme 2,
# mais par défaut pour une matrice c'est la norme de Frobenius (considérée
# donc comme un vecteur) : pour avoir la norme subordonnée 2 il faut préciser le 2
↪ en second argument.
condA = npl.cond(A,2)
print(rapportdA)
print(condA)
```

```
[ ]: # Noter ici les différentes valeurs trouvées.
#
#
#
#
```

Avec quoi peut-on majorer cette quantité (résultat de cours et travaux dirigés) ?

```
[ ]: #
#
#
```

2.4 4)

En s'inspirant de la question précédente, calculer la solution z du problème $Az = b + \delta b$ où δb est défini aléatoirement, puis évaluer la quantité

$$\frac{\|z - x\|_2}{\|x\|_2} \frac{\|b\|_2}{\|\delta b\|_2}.$$

Faire ceci pour différentes perturbations δb .

```
[ ]: db = 10**-3*np.random.rand(np.size(b))
      c = b + db
      z = # à compléter
      rapportdb = npl.norm(z - x)/npl.norm(x)*npl.norm(b)/npl.norm(db)
      print(rapportdb)
      print(condA)
```

```
[ ]: # Noter ici les différentes valeurs trouvées.
      #
      #
      #
      #
```

Avec quoi peut-on majorer cette quantité (résultat de cours et travaux dirigés) ?

```
[ ]: #
      #
      #
```

2.5 5)

Soit $D = \text{diag}(A_{1,1}, \dots, A_{n,n}) \in \mathcal{M}_5(\mathbb{R})$. On pose $A_2 = D^{-1}A$ et $b_2 = D^{-1}b$ et on considère le système linéaire $A_2x = b_2$. Construire la matrice A_2 et le vecteur b_2 en utilisant deux fois `np.diag`, sans inverser D .

Reprenre les questions 3) et 4) avec $\delta A_2 = D^{-1}\delta A$ et $\delta b_2 = D^{-1}\delta b$. Que peut-on en conclure ?

```
[ ]: A2 = # à compléter
      b2 = # à compléter
      x2 = npl.solve(A2,b2)
      dA2 = # à compléter
      B2 = A2 + dA2
      y2 = npl.solve(B2,b2)
      db2 = # à compléter
      c2 = b2 + db2
      z2 = npl.solve(A2,c2)
```

```
[ ]: print(x)
      print(x2)
      print(y)
      print(y2)
      print(z)
      print(z2)
```

```
[ ]: #rapportdA = npl.norm(y - x)/npl.norm(y)*npl.norm(A,2)/npl.norm(dA,2)
#condA = npl.cond(A,2)
print(rapportdA)
print(condA)
rapportdA2 = npl.norm(y2 - x2)/npl.norm(y2)*npl.norm(A2,2)/npl.norm(dA2,2)
condA2 = npl.cond(A2,2)
print(rapportdA2)
print(condA2)
```

```
[ ]: print(rapportdb)
print(condA)
rapportdb2 = npl.norm(z2 - x2)/npl.norm(x2)*npl.norm(b2)/npl.norm(db2)
print(rapportdb2)
print(condA2)
```

```
[ ]: # Conclusion.
#
#
#
#
```

3 Exercice 3 : deux méthodes itératives pour la résolution de systèmes linéaires, les méthodes Gauss-Seidel et de Jacobi.

Une méthode itérative pour résoudre le système linéaire $Ax = b$ consiste en une décomposition de la matrice A sous la forme $A = M - N$ puis la définition de la suite

$$\begin{cases} x_0 \in \mathbb{R}^n \\ \text{pour tout } k \in \mathbb{N}, x_{k+1} = M^{-1}Nx_k + M^{-1}b \end{cases}$$

On vérifie sans peine que si la suite est stationnaire ($x_{k+1} = x_k$ pour tout k), x_k est la solution cherchée, car $(M - N)x_k = b$ pour tout k . On identifiera en cours diverses conditions sur M et N sous lesquelles la suite *converge* (pour tout x_0) vers la solution cherchée (quelques indications apparaissent déjà dans la suite de cet exercice).

La méthode de *Gauss-Seidel* (cf. cours) est obtenue en posant $M = D - E$ et $N = F$ où D est la matrice diagonale dont la diagonale est celle de A , $-E$ correspond à la partie sous-diagonale de A et $-F$ à sa partie sur-diagonale. On définit donc la suite approximante par

$$\begin{cases} x_0 \text{ donné} \\ \forall k \in \mathbb{N}, (D - E)x_{k+1} = Fx_k + b \end{cases} \quad (\text{Gauss-Seidel})$$

Pour la méthode de *Jacobi*, on pose $M = D$ et $N = E + F$ avec les mêmes définitions ; l'itération s'écrit

$$\begin{cases} x_0 \text{ donné} \\ \forall k \in \mathbb{N}, Dx_{k+1} = (E + F)x_k + b \end{cases} \quad (\text{Jacobi})$$

3.0.1 1)

Utiliser les commandes Python `numpy.tril` et `numpy.triu` pour définir D , E et F et vérifier que $D - E - F = A$. **Attention aux signes.**

```
[ ]:
```

3.0.2 2)

Soit $n \in \mathbb{N}^*$, $B \in \mathcal{M}_n(\mathbb{R})$ et $c \in \mathbb{R}^n$. Soit la suite récurrente définie par :

$$\begin{cases} x_0 \in \mathbb{R}^n \\ \text{pour tout } k \in \mathbb{N}, x_{k+1} = Bx_k + c \end{cases}$$

Montrer que la suite $(x_k)_{k \in \mathbb{N}}$ converge, quel que soit x_0 , si et seulement si $\rho(B) < 1$. On pourra introduire la quantité $x_k - \bar{x}$ où \bar{x} est la solution de $\bar{x} = B\bar{x} + c$.

```
[ ]: #
#
#
#
#
#
#
#
#
#
#
#
#
#
#
#
```

En déduire une condition nécessaire et suffisante pour que les méthodes de Jacobi et Gauss-Seidel convergent.

```
[ ]: #
#
```

Prédire, à l'aide de Python, le comportement (convergence ou non) de ces deux méthodes pour la matrice A de l'exercice précédent.

```
[ ]: # À compléter.
```

3.0.3 3)

Voici une fonction qui calcule `niter` itérations de la méthode de Gauss-Seidel, et qui renvoie la solution approchée `u` et la matrice `res` contenant la suite des itérés calculés : x_0, x_1, x_2, \dots

```
[ ]: def gauss_seidel(A,b,x0,niter):
    D = np.diag(np.diag(A))
    E = -np.tril(A) + D
    F = -np.triu(A) + D
    sol = npl.solve(A,b)
    u = x0
    res = x0
    resn = npl.norm(u-sol)
```

```

for k in range(niter):
    u = npl.solve((D-E), (np.dot(F,u)+b))
    res = np.vstack((res, u))
    resn = np.vstack((resn, npl.norm(u-sol)))
return(u, res, resn)

```

Tester cette fonction (choisir `x0` et `niter`). Que contiennent `u`, `res` et `resn` ? Comment afficher l'erreur entre la solution approchée et la solution exacte ?

```
[ ]: #
#
#
#
```

```
[ ]: # À compléter.
```

3.0.4 4) Vitesse de convergence.

On note pour tout $k \in \mathbb{N}$, $e_k = \|x_k - x\|$, où x est la solution de $Ax = b$, une norme de l'erreur à l'itération k . Lors de l'utilisation d'une méthode itérative, s'il existe deux constantes positives α et C telles que

$$\lim_{k \rightarrow +\infty} \frac{e_{k+1}}{(e_k)^\alpha} = C,$$

on dit que l'ordre de la méthode est α et que sa vitesse de convergence est C .

On s'intéresse à l'ordre et la vitesse de convergence de la méthode de Gauss-Seidel. Pour cela, on va tracer des fonctions de l'erreur. Exécuter la suite d'instructions suivante et interpréter la figure tracée.

```
[ ]: x0 = np.array([1,5,1,5,1])
n = 50
u, res, resn = gauss_seidel(A, b, x0, n)
plt.figure("Étude de la vitesse de convergence de la méthode de
↳ Gauss-Seidel", figsize=(14,8))
plt.plot(np.log(resn[:n]), np.log(resn[1:]), '*')
plt.grid()
plt.show()
resn = resn.flatten()
pente, oao, _, _, _ = scipy.stats.linregress(np.log(resn[:n]), np.log(resn[1:]))
print("pente : ", pente)
print("ordonnée à l'origine : ", oao)
```

Que calcule la commande `linregress` ? Où, sur la figure, peut-on retrouver les nombres calculés ?

```
[ ]: #
#
#
#
#
```

3.0.5 5)

Refaire les questions 3) et 4) pour la méthode de Jacobi.

```
[ ]: 
```

```
[ ]: 
```

```
[ ]: 
```

4 Exercice 4 : factorisation QR par Gram-Schmidt (cas de matrices à coefficients réels).

4.0.1 1)

Programmer une fonction `QR_GS` qui à une matrice réelle A associe sa factorisation QR obtenue par l'algorithme de Gram-Schmidt vu en cours.

La tester sur une matrice de $\mathcal{M}_3(\mathbb{R})$.

```
[ ]: def QR_GS(A):  
    m,n = A.shape # m doit être supérieur ou égal à n, m = n si A est carrée.  
    R = np.zeros((n,n))  
    Q = np.zeros((m,n))  
    for j in range(n):  
        Q[:,j] = A[:,j].copy()  
        for k in range(j):  
            # à compléter  
        Q[:,j] = Q[:,j]/np.linalg.norm(Q[:,j])  
    R = np.dot(np.transpose(Q),A)  
    return (Q,R)
```

4.0.2 2)

Tester l'algorithme avec la matrice

$$B = \begin{pmatrix} 1 & 1 & 0 \\ 2 & 1 & 0 \\ 1 & 1 & 1 \end{pmatrix}$$

et estimer la précision du résultat en calculant la norme de $Q^T Q - I_3$ ainsi que la norme de $B - QR$.

```
[ ]: B = np.array([[1,1,0],[2,1,0],[1,1,1]])  
Q,R = QR_GS(B)  
print("Q = ",Q)  
print("R = ",R)  
print("Q^T Q - I = ", ) # à compléter  
print("QR - B = ", ) # à compléter
```

4.0.3 3)

Même question avec

$$B = \begin{pmatrix} 1 & 0.1 & 0.01 & 0.001 & 0.0001 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1.5 & 2.25 & 3.375 & 5.0625 \\ 1 & 2 & 4 & 8 & 16 \\ 1 & 3 & 9 & 27 & 81 \end{pmatrix}.$$

```
[ ]: B = np.array([[1,0.1,0.01,0.001,0.0001],[1,1,1,1,1],[1,1.5,2.25,3.375,5.0625],[1,2,4,8,16],[1,3,9,27,81]])
      Q,R = QR_GS(B)
      print("Q = ",Q)
      print("R = ",R)
      print("||Q^T Q - I|| = ", ) # à compléter
      print("||QR - B|| = ", ) # à compléter
```

5 Exercice 5 : factorisation QR par les symétries de Householder.

Le but de cet exercice est d'obtenir la décomposition $A = QR$ par l'algorithme de Householder, pour une matrice réelle. Il consiste à multiplier la matrice A de départ par une suite de matrices orthogonales très simples pour obtenir une matrice triangulaire supérieure.

Notations. Soit $n \in \mathbb{N}^*$. Dans la suite, les vecteurs de \mathbb{R}^n sont identifiés à des vecteurs colonnes et $\|\cdot\|$ désigne la norme euclidienne canonique. Ainsi, pour tout $u \in \mathbb{R}^n$, $\|u\|^2 = u^T u$.

5.1 Première partie : définition de l'algorithme.

5.1.1 1)

À tout vecteur $u \in \mathbb{R}^n$ on associe la matrice de Householder définie par

$$H(u) = \begin{cases} I_n - 2 \frac{uu^T}{\|u\|^2} & \text{si } u \neq 0, \\ I_n & \text{sinon.} \end{cases}$$

a. Montrer que, pour tout $u \in \mathbb{R}^n$, $H(u)$ est symétrique et orthogonale.

$H(u)$ est la matrice de la symétrie orthogonale par rapport à l'hyperplan orthogonal à u .

Faire un dessin.

```
[ ]: #
#
#
#
#
#
#
#
#
#
#
```

b. Soit e un vecteur unitaire de \mathbb{R}^n .

Montrer que, pour tout $v \in \mathbb{R}^n$, si v et e ne sont pas colinéaires, alors

$$H(v + \|v\|e)v = -\|v\|e \quad \text{et} \quad H(v - \|v\|e)v = \|v\|e.$$

```
[ ]: #  
#  
#  
#  
#  
#  
#  
#  
#  
#
```

5.1.2 2)

Soit $A \in \mathcal{M}_n(\mathbb{R})$.

a. Déterminer une matrice de Householder H telle que la matrice HA n'ait que des zéros sous la diagonale dans sa première colonne.

```
[ ]: #  
#  
#  
#  
#  
#  
#  
#  
#  
#
```

b. Construire une suite de matrices de Householder $(H^{(k)})_{1 \leq k \leq n-1}$ et une suite de matrices $(A^{(k)})_{0 \leq k \leq n-1}$ telles que

i) $A^{(0)} = A$;

ii) pour tout $0 \leq k \leq n-2$, $A^{(k+1)} = H^{(k+1)}A^{(k)}$;

iii) $A^{(n-1)}$ est triangulaire.

```
[ ]: #  
#  
#  
#  
#  
#  
#  
#  
#  
#
```

5.2 Seconde partie : mise en œuvre.

5.2.1 1)

Programmer une fonction `householder` qui à un vecteur v associe la matrice de Householder $H(v)$.

Programmer une fonction `symetrie` qui à un vecteur e et un vecteur x associe le vecteur $x + \|x\|e$ (ou le vecteur $x - \|x\|e$).

Les tester.

```
[ ]: # Pour une matrice réelle :
def householder(v):
    n = np.size(v)
    Hv = # à compléter
    return(Hv)
def symetrie(e,x): # e doit être normé, et x non nul, de même dimension.
    n = np.size(e)
    lamb = np.dot(e.T,x)/abs(np.dot(e.T,x))*npl.norm(x)
    if npl.norm(x + lamb*e) > npl.norm(x - lamb*e):
        # On choisit le plus grand des deux vecteurs possibles, pour des raisons de
        ↪ stabilité de l'algorithme.
        v = # à compléter
    else:
        v = # à compléter
    return(v)

v = np.array([[1,1,1]])
v = np.transpose(v)
e = np.array([[1,0,0]])
e = np.transpose(e)
print(np.dot(householder(symetrie(e,v)),v))
```

5.2.2 2)

Programmer une fonction `QR_HH` qui à une matrice réelle A associe une factorisation QR de A obtenue par l'algorithme de Householder (cette fonction utilisera explicitement les fonctions `householder` et `symetrie`, au bénéfice de la lisibilité du programme mais aux dépens de sa vitesse d'exécution). La tester sur les matrices de l'exercice 4.

```
[ ]: def QR_HH(A):
    m,n = A.shape
    R = np.zeros((n,n))
    Q = np.zeros((m,n))
    H = np.eye(m,m)
    for j in range(n):
        x = np.zeros((n-j,1))
        x[:,0] = A[j:,j]
        e = np.zeros((n-j,1))
        e[0,0] = 1.
        if npl.norm(x) > 0.:
            Hj = np.eye(m,m)
            Hj[j:,j:] = # à compléter
```

```

        A = np.dot(Hj,A)
        H = np.dot(Hj,H)
    R = A
    Q = np.conj(H).T
    return(Q,R)

```

```

[ ]: B = np.array([[1,1,0],[2,1,0],[1,1,1]])
      Q,R = QR_HH(B)
      print("Q = ",Q)
      print("R = ",R)
      print("QR - B = ",np.dot(Q,R) - B)

```

```

[ ]: B = np.array([[1,0.1,0.01,0.001,0.0001],[1,1,1,1,1],[1,1.5,2.25,3.375,5.
↪0625],[1,2,4,8,16],[1,3,9,27,81]])
      Q,R = QR_HH(B)
      print("Q = ",Q)
      print("R = ",R)
      print("||Q^T Q -I|| = ",npl.norm(np.dot(np.transpose(Q),Q) - np.eye(5,5)))
      print("||QR - B|| = ",npl.norm(np.dot(Q,R) - B))

```

5.3 Comparer la précision des méthodes de factorisation QR de Gram-Schmidt et de Householder sur la matrice de Hilbert en dimension 30.

La matrice de Hilbert $H \in \mathcal{M}_n(\mathbb{R})$ est définie par

$$H_{i,j} = \frac{1}{i+j-1}, \quad i, j = 1, \dots, n.$$

5.3.1 1)

Construire la matrice de Hilbert en dimension $n \in \mathbb{N}$.

```

[ ]: def hilbert(n):
      H = np.empty((n,n))
      for i in range(n):
          for j in range(n):
              H[i,j] = # à compléter
      return(H)

```

5.3.2 2)

Calculer avec python le conditionnement de la matrice pour $n = 30$.

```

[ ]: H = hilbert(30)
      print(H)
      print(npl.cond(H))

```

5.3.3 3)

Calculer une factorisation QR de cette matrice avec l'algorithme de Gram-Schmidt et estimer la précision du résultat en calculant la norme de $Q^T Q - I_{30}$ ainsi que la norme de $H - QR$.

```
[ ]: Q,R = QR_GS(H)
I = np.eye(len(H))
print("||Q^T Q - I|| = ", npl.norm(np.dot(np.transpose(Q),Q) - I))
print("||QR - H|| = ", npl.norm(np.dot(Q,R) - H))
```

5.3.4 4)

Calculer une factorisation QR de cette matrice avec l'algorithme de Householder et estimer la précision du résultat en calculant la norme de $Q^T Q - I_{30}$ ainsi que la norme de $H - QR$.

```
[ ]: Q,R = QR_HH(H)
I = np.eye(len(H))
print("||Q^T Q - I|| = ", npl.norm(np.dot(np.transpose(Q),Q) - I))
print("||QR - H|| = ", npl.norm(np.dot(Q,R) - H))
```

Commenter.

```
[ ]: #
#
#
#
#
#
```

5.3.5 5) Une application de la factorisation QR

Calculer le déterminant d'une matrice (par exemple une matrice de Hilbert) en utilisant sa factorisation QR . On pourra comparer le résultat avec celui de la fonction `npl.det`.

```
[ ]: H = hilbert(10)
Q,R = QR_GS(H)
determinant = 1.
for j in range(R.shape[0]):
    determinant = determinant* # à compléter
print(determinant)
Q,R = QR_HH(H)
determinant = 1.
for j in range(R.shape[0]):
    determinant = determinant* # à compléter
print(determinant)
print(npl.det(H))
```