

```
#!/usr/bin/env python3
# -*- coding: utf-8 -*-
# """
# Created on Mon Dec 11 17:44:18 2017
#
# @author: christianehelzel
# """
```

1 10. Vorlesung: Die QR Zerlegung

Ziel: Finde eine Zerlegung der Matrix A der Form

$$A = QR$$

mit Q orthogonale bzw. unitäre Matrix und R obere Dreiecksmatrix

```
import numpy as np
import numpy.linalg as npl

A = np.array([ [-1, 1, 4, -1], [3, 8, 1, -4], [7., 3, -1, 2], \
               [2, -4, -1, 6], [1,0,1,0] ])
```

reduzierte QR Zerlegung (default)

```
Q,R = npl.qr(A)
```

vollständige QR Zerlegung

```
Q,R = npl.qr(A,mode='complete')
```

Wiederholung: Wir verwenden wieder unsere Funktion SolveR

```
# Löse R x = b
def SolveR(R,b):
    import numpy as np

    n = len(b)
    x = np.zeros(n)

    x[-1] = b[-1]/R[-1,-1]
    for k in range(n-2,-1,-1):
        x[k] = (b[k]-np.sum(R[k,k+1:]*x[k+1:]))/R[k,k]
    return x
```

1.1 Löse lineares Gleichungssystem $Ax = b$ unter Verwendung der QR Zerlegung

Löse lineares Gleichungssystem $Ax = b$

Beispiel:

$$10x - 7y = 7$$

$$-3x + 2y + 6z = 4$$

$$5x - y + 5z = 6$$

```
import numpy as np

A = np.array([[10., -7, 0], [-3, 2, 6], [5, -1, 5]])
b = np.array([7., 4, 6])

Q,R = npl.qr(A)
x = SolveR(R,Q.T@b)
```

Die QR Zerlegung einer $m \times n$ Matrix A mit $m > n$ kann benutzt werden um das überbestimmte LGS $Ax = b$ im Sinne der Methode der kleinsten Fehlerquadrate zu lösen

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

x = np.linspace(0, 10, 5)
A = np.vstack([x, np.ones(len(x))]).T
m,n = A.shape

Q,R = npl.qr(A)
# liefert mxn (Spalten) orthogonale Matrix Q
# nxn obere Dreiecksmatrix R


# b ist rechte Seite des linearen Gleichungssystems
f = np.poly1d([5, 1])
b = f(x) + 6*np.random.normal(size=len(x))

# Löse Ax=b unter Verwendung der QR-Zerlegung
# d.h. löse R x = Q.T b

coeff = SolveR(R,Q.T@b)
lsf = coeff[0]*x+coeff[1]

plt.close('all')
plt.figure()
plt.plot(x,b,'r.')
plt.plot(x, lsf)
```

| [<matplotlib.lines.Line2D at 0x7f17bf7b6860>]



Beachte: dieser Ansatz ist weniger anfällig gegenüber Rundungsfehler als die Lösung von $A.T A x = A.T b$

Berechne QR Zerlegung unter Verwendung von Gram-Schmidt

```
def GramSchmidt (A) :
    import numpy as np
    import numpy.linalg as npl

    m, n = A.shape;
    Q = np.zeros([m,n])      # Null-Array der Größe mxn
    R = np.zeros([n,n])      # Null-Array der Größe nxn
    for j in range(n):
        Q[:,j] = A[:,j];
        # Orthogonalisiere A[:,j] gegen Q[:,1], ..., Q[:,j-1]
        for i in range(j):
            R[i,j]=Q[:,i].T*A[:,j]
            Q[:,j]=Q[:,j]-R[i,j]*Q[:,i]
        # Normiere Q[:,j]
        R[j,j]=npl.norm(Q[:,j])
        Q[:,j]=Q[:,j]/R[j,j]
    return Q, R
```

Berechne QR Zerlegung unter Verwendung des modifizierten Gram-Schmidt Verfahrens

```
def ModGramSchmidt (A) :
    import numpy as np
    import numpy.linalg as npl

    m, n = A.shape;
```

```

Q = np.zeros([m,n])      # Null-Array der Größe mxn
R = np.zeros([n,n])     # Null-Array der Größe nxn

for j in range(n):
    Q[:,j] = A[:,j];
    # Orthogonalisiere A[:,j] gegen Q[:,1], ..., Q[:,j-1]
    for i in range(j):
        # Berechne die Koeffizienten R[i,j] mit aktuellem Q[:,j] statt A[:,j]
        R[i,j]=Q[:,i].T@Q[:,j]
        Q[:,j]=Q[:,j]-R[i,j]*Q[:,i]
    # Normiere Q[:,j]
    R[j,j]=npl.norm(Q[:,j])
    Q[:,j]=Q[:,j]/R[j,j]
return Q, R

```

1. Genauigkeitstest

```

import numpy as np

d = 1E-8
A = np.array([[1.,1.,1.],[d,0.,0.],[0.,d,0.],[0.,0.,d]])
Q1,R1 = GramSchmidt(A)
print(Q1.T@Q1)
Q2,R2 = ModGramSchmidt(A)
print(Q2.T@Q2)

```

```

[[ 1.00000000e+00 -7.07106781e-09 -7.07106781e-09]
 [ -7.07106781e-09 1.00000000e+00 5.00000000e-01]
 [ -7.07106781e-09 5.00000000e-01 1.00000000e+00]]
[[ 1.00000000e+00 -7.07106781e-09 -4.08248290e-09]
 [ -7.07106781e-09 1.00000000e+00 1.11022302e-16]
 [ -4.08248290e-09 1.11022302e-16 1.00000000e+00]]

```

2. Genauigkeitstest

```

import numpy as np
import numpy.linalg as npl
import matplotlib.pyplot as plt

n = 100
errGS = np.zeros([n])
errMGS = np.zeros([n])
errQR = np.zeros([n])
dim = np.zeros([n])

for i in range(100):
    A = np.random.uniform(0, 1, (i+1, i+1))
    Q1,R1 = GramSchmidt(A)
    errGS[i] = np.max(np.abs(Q1.T@Q1-np.eye(i+1)))
    Q2,R2 = ModGramSchmidt(A)
    errMGS[i] = np.max(np.abs(Q2.T@Q2-np.eye(i+1)))
    Q3,R3 = npl.qr(A)
    errQR[i] = np.max(np.abs(Q3.T@Q3-np.eye(i+1)))
    dim[i] = i+1

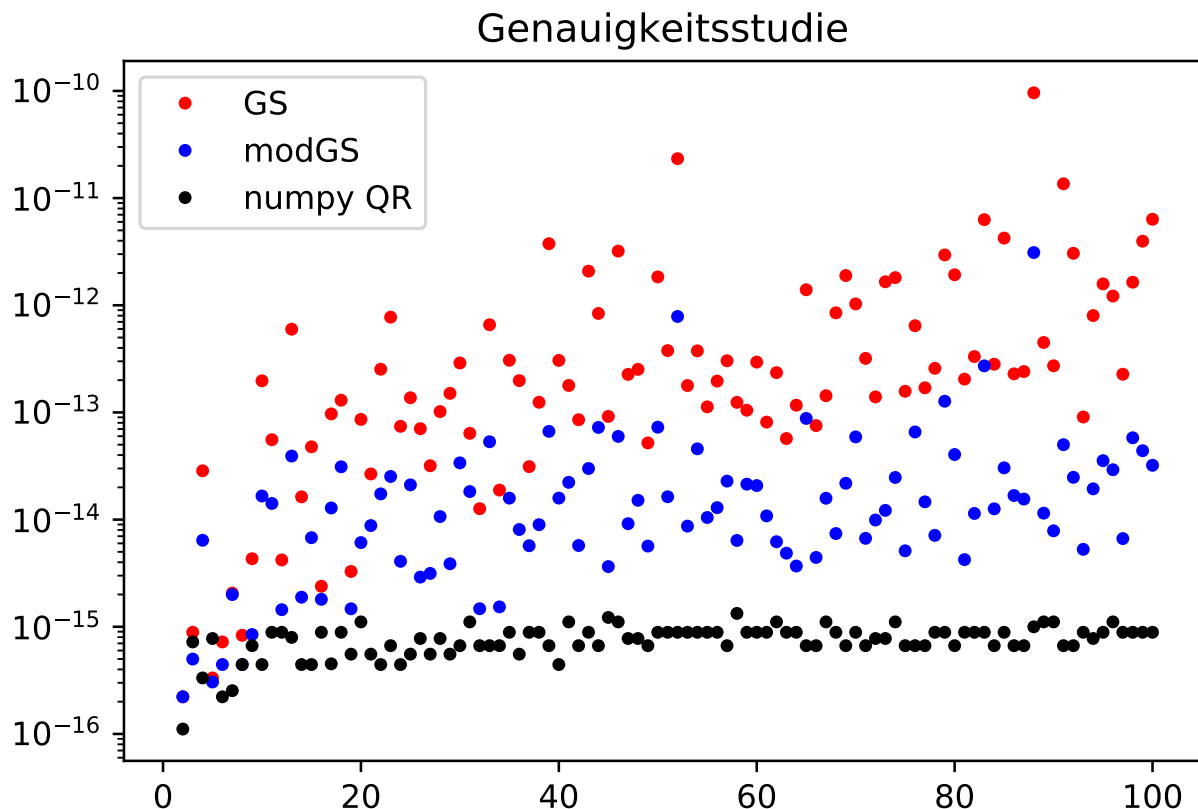
plt.close('all')

```

```
plt.figure()

plt.semilogy(dim, errGS, 'r.')
plt.semilogy(dim, errMGS, 'b.')
plt.semilogy(dim, errQR, 'k.')
plt.legend(['GS', 'modGS', 'numpy QR'])
plt.title('Genauigkeitsstudie')
```

```
Text(0.5,1,'Genauigkeitsstudie')
```



Weitere Informationen zur QR-Zerlegung und zu Gram-Schmidt finden Sie in den Kapiteln 7 und 8 des Buches "Numerical Linear Algebra" (Trefethen und Bau) (siehe Vorlesungsseite)

1.2 QR Algorithm: iterativer Algorithmus zur Berechnung der Eigenwerte von A

Für symmetrische Matrizen konvergiert die iterativ berechnete Matrix (Anew) gegen eine Diagonalmatrix. Da Anew und A selbstähnlich sind, liefern die Diagonalelemente von Anew eine Approximation an die Eigenwerte von A

```
A = np.array([[1., 3., 4.], [3., 1., 2.], [4., 2., 1.]])
nit = 100

Anew = A.copy()
for i in range(nit):
    Q,R = npl.qr(Anew)
    Anew = R@Q
```

für symmetrische Matrizen konvergiert der Prozess gegen eine Diagonalmatrix

```
eval_estimate = np.diag(Anew)
```

Zum Vergleich: Berechne EWe mit `npl.eig`

```
eval_ref, evec = npl.eig(A)
```

Weitere Informationen zu diesem Algorithmus finden Sie in Kapitel 28 des Buches "Numerical Linear Algebra" (Trefethen und Bau) (siehe Vorlesungsseite)