

Programmieraufgabe I (9 + 8 + 4 + 4 = 25 Punkte)

Abgabe in der Woche vom 5. bis 9. November

```
In [1]: import numpy as np
import matplotlib.pyplot as plt
```

Die grundlegenden Operationen der linearen Algebra (d.h. Summen, Skalarprodukte, Norm, Matrix-Vektor-Produkt, etc.) sind für numpy-arrays bereits implementiert und dürfen hier verwendet werden.

Teilaufgabe a)

Implementieren Sie eine Funktion, die als Input ein Matrix A (als numpy-array) erhält und die reduzierte QR-Zerlegung (\hat{Q} , \hat{R} jeweils als numpy-arrays) zurückgibt. Als Subroutine empfiehlt es sich, die Anwendung der Householder-Transformation separat zu implementieren.

```
In [64]: def myqr(A):
    ## Diese Funktion soll die reduzierte QR-Zerlegung von A berechnen und Q, R (in der Vorlesung  $\hat{Q}$ ,  $\hat{R}$ ) zurückgeben...
    return Q,R
def householder(arg, w):
    ## Diese Funktion soll eine Householder-Transformation  $I - 2ww^T$  auf d as Argument arg (Matrix oder Vektor) anwenden.
    return result
```

Testen Sie Ihre eigene Implementierung, indem Sie eine zufällige 5×4 -Matrix erzeugen und deren mit Ihrer Implementierung generierte QR-Zerlegung mit der in numpy bereits implementierten QR-Zerlegung vergleichen.

```
In [65]: ## Hinweis: Verwenden Sie die Generierung zufälliger Matrizen aus numpy...
```

Teilaufgabe b)

Implementieren Sie die QR-basierte Lösungsstrategie für das Least-Squares Problem $\min_x \|Ax - b\|$: Die Funktion soll als Input die Matrix A und den Vektor b (beide als numpy-array) erhalten und die Lösung x_{\min} zurückgegeben.

Die Lösung eines Gleichungssystems mit oberer Dreiecksstruktur sollen Sie als eigene Routine programmieren. (Der lineare Löser aus numpy soll hier nicht verwendet werden.)

```
In [4]: def myuppertriangularsolver(A,b):
        ## Löst die Gleichung Ax = b, wobei A eine obere Dreiecksmatrix mit stri
        kt positiven Diagonalelementen ist. ##
        return x
def myleastsquares(A,b):
        ## Löst das least squares problem $min_x ||Vert Ax-b ||rVert_2$.
        return xmin
```

Testen Sie Ihre Implementierung an Aufgabe 1b) von Übungsblatt Nr. 2:

```
In [66]: b = np.array([2, 3, 3, -2])
A = np.array([[1, -2, 4], [1, -1, 1], [1,1,1], [1,2,4]])
xtrue=np.array([4, -4./5, -1])
## Test: ...
```

Teilaufgabe c)

Es sei das Intervall $I = (0, 1)$ gegeben. Die folgende Funktion gibt einen Vektor von x -Werten aus I sowie die geringfügig zufällig gestörten zugehörigen y -Werte $y \approx f(x)$ zurück.

```
In [58]: def noisyfunction(fun, numberofpoints, noisemax):
        xvals = np.random.rand(numberofpoints)
        yvals = np.zeros(numberofpoints)
        for k in range(numberofpoints):
            yvals[k] = fun(xvals[k]) + 2*noisemax*(np.random.rand()-0.5)
        return xvals, yvals
```

Es sei eine Funktion $F: \mathbb{R} \times \mathbb{N} \rightarrow \mathbb{R}$ gegeben, z.B. $F_{\text{pol}}(x, l) := x^l$ oder $F_{\text{sin}}(x, l) = \sin(\pi l x)$, derart, dass durch $f_l(x) := F(x, l)$ eine "sinnvolle" Familie von Basisfunktionen definiert wird.

Für gegebene Datenpunkte $(x_1, y_1), \dots, (x_m, y_m)$ und $n \in \mathbb{N}$ wollen wir einen Koeffizientenvektor $c = (c_0, \dots, c_n)$ bestimmen, der das Least-Squares Problem $\min_{c \in \mathbb{R}^n} \sum_{k=1}^m |\sum_{l=1}^n c_l f_l(x_k) - y_k|^2$ löst. Schreiben Sie dazu die Funktion "myregression" mit folgenden Inputs:

- xvals, yvals: Arrays mit den gegebenen Wertepaaren
- funfamily: Funktion F für die Erzeugung der Basisfunktionen (siehe oben)
- degree: entspricht n , der Anzahl der verwendeten Basisfunktionen
- xtoevaluate: array mit x -Werten, an denen die gefundene Regressions-Lösung ausgewertet werden soll

Ausgegeben werden soll der Koeffizientenvektor coeffvec sowie die Auswertung y der Regressions-Lösung an den in xtoevaluate gegebenen x-Werten.

```
In [68]: def myregression(xvals, yvals, funfamily, degree, xtoevaluate):  
  
    ## ... ##  
  
    return y, coeffvec  
  
    ## Implementierung der Basis-Familien $F_{Pol}$ bzw. $F_{sin}$ von oben:  
    def polynomialfamily(x,l):  
        return x**l  
  
    def sinefamily(x,l):  
        return np.sin(np.pi*x*(l+1))
```

Teilaufgabe d)

Testen Sie Ihre Implementierung für die Lösung des Least-Squares Problems mit den unten erzeugten Wertepaaren:

- Plotten Sie dazu jeweils die verrauschten Wertepaare sowie die Regressionsfunktion.
- Variieren Sie die Anzahl der Basisfunktionen bzw. die Wahl der Familie von Basisfunktionen.

Erklären Sie, weshalb die Lösung des Least-Squares Problems für die Approximation von $x - \frac{1}{2}$ mittels Sinus-Schwingungen sehr viel instabiler zu sein scheint als die Approximation des Sinus mit Polynomen.

```
In [71]: def fun_1(x):  
    return np.sin(2*np.pi*x)  
xvals_1,yvals_1=noisyfunction(fun_1, 50, 0.1)  
  
def fun_2(x):  
    return x-0.5  
xvals_2, yvals_2 = noisyfunction(fun_2, 50, 0.1)  
  
## ...
```

In []: