

Fatoração QR

Prof. Alexandre Salles da Cunha e Profa. Ana Paula Couto



UNIVERSIDADE FEDERAL
DE MINAS GERAIS



$A = QR$ onde $A \in \mathbb{R}^{m \times n}$, $Q \in \mathbb{R}^{m \times n}$, $R \in \mathbb{R}^{n \times n}$

- Hipótese inicial: A possui posto completo: $r(A) = n$ (vamos relaxar esta hipótese em breve).
- Q possui n colunas ortonormais.
- R é triangular superior e $r_{ii} \neq 0$ para qualquer i .

$\Rightarrow$ Se o sistema é quadrado ($m = n$) e precisamos resolver $Ax = b$ temos:

$$\Rightarrow Q(Rx) = b \rightarrow Qy = b \rightarrow y = Q^T b \rightarrow Rx = Q^T b$$

(mais estável numericamente pois Q é ortogonal).

- Matrizes ortogonais são excelentes para computação científica: as quantidades computadas não crescem muito, dado que Q tem norma unitária; menores erros numéricos.

- **Notação:**

- $A_i \in \mathbb{R}^m : i = 1, \dots, n$ são as colunas de A .
- $q_i \in \mathbb{R}^m : i = 1, \dots, n$ são as colunas de Q .

- Subespaços são idênticos - estrutura a ser explorada no algoritmo:

$$\begin{aligned} \text{span}\{A_1\} &= \text{span}\{q_1\} \\ \text{span}\{A_1, A_2\} &= \text{span}\{q_1, q_2\} \\ &\vdots \\ \text{span}\{A_1, \dots, A_n\} &= \text{span}\{q_1, q_2, \dots, q_n\} \end{aligned}$$

- Desejamos encontrar uma base mais conveniente para $\mathcal{C}(A)$.
Mais conveniente significa "base ortonormal".
- Além disso, sabemos que:
 $\text{span}\{A_1\} \subseteq \text{span}\{A_1, A_2\} \subseteq \dots \subseteq \text{span}\{A_1, A_2, \dots, A_n\}$

$$\left[\begin{array}{c|c|c|c} A_1 & A_2 & \cdots & A_n \end{array} \right] = \left[\begin{array}{c|c|c|c} q_1 & q_2 & \cdots & q_n \end{array} \right] \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ & r_{22} & \cdots & r_{2n} \\ & & \ddots & \vdots \\ & & & r_{nn} \end{bmatrix} \quad (1)$$

Equivalentemente, o sistema (1) corresponde a:

- $A_1 = r_{11}q_1$
- $A_2 = r_{12}q_1 + r_{22}q_2$
- $\dots$
- $A_i = \sum_{k=1}^i r_{ki}q_k$
- $A_n = r_{1n}q_1 + r_{2n}q_2 + \cdots + r_{nn}q_n$

onde:

- $q_i^T q_j = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$
- $r_{ii} \neq 0 : i = 1, \dots, n$ (como consequência de $r(A) = n$).

- Baseado na ideia de ortogonalização de bases de Gram-Schmidt.
- Do ponto de vista teórico e conceitual, a ortogonalização de Gram-Schmidt é fundamental, permitindo demonstrar diversas propriedades da fatoração QR .
- Na sequência, apresentamos o algoritmo clássico baseado em Gram-Schmidt.
- Posteriormente, discutiremos como modificá-lo visando redução de erros numéricos.

Invariante do algoritmo:

No início da iteração j :

- dispomos de $j - 1$ colunas ortonormais $q_i : i = 1, \dots, j - 1$
- estas colunas satisfazem:

$$\text{span}\{A_1, \dots, A_{j-1}\} = \text{span}\{q_1, \dots, q_{j-1}\}$$

Nosso objetivo na iteração j é determinar q_j tal que:

- $\text{span}\{A_1, \dots, A_j\} = \text{span}\{q_1, \dots, q_j\}$
- $q_j \perp \text{span}\{q_1, \dots, q_{j-1}\}$
- $\|q_j\| = 1$

O processo empregado para se determinar q_j como desejado acima é a *Ortonormalização de Gram-Schmidt*.

- Vamos formalizar o algoritmo e, em paralelo, aplicá-lo para obter a fatoração de uma matriz 3×3 .
- Enfatizamos que a fatoração $A = QR$ não se destina apenas a fatorar matriz quadradas.

$$A = \begin{bmatrix} 1 & 2 & 3 \\ -1 & 0 & -3 \\ 0 & -2 & 3 \end{bmatrix}.$$

Observe que as colunas $A_1 = \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}$, $A_2 = \begin{bmatrix} 2 \\ 0 \\ -2 \end{bmatrix}$, $A_3 = \begin{bmatrix} 3 \\ -3 \\ 3 \end{bmatrix}$ são linearmente independentes.

Primeira iteração - $j = 1$:

- Dado A_1 desejamos $\text{span}\{q_1\} = \text{span}\{A_1\}$, $\|q_1\| = 1$.
- Então fazemos $q_1 = \frac{A_1}{\|A_1\|}$
- Ou seja, $r_{11} = \|A_1\|$

Primeira iteração - $j = 1$:

$$A_1 = \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}, q_1 = \frac{\sqrt{2}}{2} \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}, r_{11} = \sqrt{2}.$$

Iteração típica - $j \in \{2, \dots, n\}$: Dada a nova coluna A_j e $\{q_1, q_2, \dots, q_{j-1}\}$ satisfazendo

$$\text{span}\{A_1, \dots, A_{j-1}\} = \text{span}\{q_1, \dots, q_{j-1}\}$$

calculamos q_j , da seguinte forma:

- ❶ Calculamos a projeção p_j de A_j no subespaço $\text{span}\{q_1, \dots, q_{j-1}\}$

$$p_j = (q_1^T A_j)q_1 + (q_2^T A_j)q_2 + \dots + (q_{j-1}^T A_j)q_{j-1}$$

- ❷ Da expressão acima, temos: $r_{ij} = q_i^T A_j$ para $i = 1, \dots, j-1$.

- ❸ Calculamos o veto "erro": $v_j = A_j - p_j$
(recorde-se de que $(A_j - p_j) \perp \text{span}\{q_1, \dots, q_{j-1}\}$)

- ❹ Normalizamos o erro: $q_j = \frac{v_j}{r_{jj}}$, e $r_{jj} = \|v_j\|$

Segunda iteração - $j = 2$:

- Dados: $q_1 = \frac{\sqrt{2}}{2} \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}$, $A_2 = \begin{bmatrix} 2 \\ 0 \\ -2 \end{bmatrix}$
- Projeção: $p_2 = (q_1^T A_2)q_1 = \sqrt{2}q_1 = \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}$, $r_{12} = \sqrt{2}$.
- Erro: $v_2 = A_2 - p_2 = \begin{bmatrix} 1 \\ 1 \\ -2 \end{bmatrix}$, $\|v_2\| = r_{22} = \sqrt{6}$.
- $q_2 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 1 \\ -2 \end{bmatrix}$

Terceira iteração - $j = 3$:

- Dados: $q_1 = \frac{\sqrt{2}}{2} \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}$, $q_2 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 1 \\ -2 \end{bmatrix}$, $A_3 = \begin{bmatrix} 3 \\ -3 \\ 3 \end{bmatrix}$

- Projeção:

$$p_3 = (q_1^T A_3)q_1 + (q_2^T A_3)q_2 = 3\sqrt{2}q_1 - \sqrt{6}q_2 = \begin{bmatrix} 2 \\ -4 \\ 2 \end{bmatrix},$$

$$r_{13} = 3\sqrt{2}, r_{23} = -\sqrt{6}.$$

- Erro: $v_3 = A_3 - p_3 = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$.

- $q_3 = \frac{\sqrt{3}}{3} \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$, $r_{33} = \sqrt{3}$.

Fatoração concluída:

$$\begin{bmatrix} 1 & 2 & 3 \\ -1 & 0 & -3 \\ 0 & -2 & 3 \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{2}}{2} & \frac{\sqrt{6}}{6} & \frac{\sqrt{3}}{3} \\ -\frac{\sqrt{2}}{2} & \frac{\sqrt{6}}{6} & \frac{\sqrt{3}}{3} \\ 0 & -\frac{\sqrt{6}}{3} & \frac{\sqrt{3}}{3} \end{bmatrix} \begin{bmatrix} \sqrt{2} & \sqrt{2} & 3\sqrt{2} \\ & \sqrt{6} & -\sqrt{6} \\ & & \sqrt{3} \end{bmatrix}$$

- Passo de projeção:

$$p_j = (q_1^T A_j)q_1 + (q_2^T A_j)q_2 + \cdots + (q_{j-1}^T A_j)q_{j-1}$$

$$p_j = q_1(q_1^T A_j) + q_2(q_2^T A_j) + \cdots + q_{j-1}(q_{j-1}^T A_j)$$

$$p_j = \sum_{i=1}^{j-1} q_i q_i^T A_j$$

- Calculando a diferença ou erro:

$$v_j = A_j - p_j$$

$$v_j = I A_j - \sum_{i=1}^{j-1} q_i q_i^T A_j$$

$$v_j = (I - Q_{j-1} Q_{j-1}^T) A_j$$

onde Q_{j-1} é a matriz $m \times (j-1)$ com as primeiras $j-1$ colunas de Q .

- $(I - Q_{j-1} Q_{j-1}^T)$ projeta A_j em $\text{span}\{q_1, \dots, q_{j-1}\}^\perp$.

Atenção: Assumimos posto completo nesta implementação.

```
function [Q,R] = Fatoracao_QR_Classica(A)
    [m,n] = size(A)
    R = zeros(n,n)
    Q = zeros(m,n)
    for j = 1:n
        V = A(:,j)
        for i = 1:j-1
            R(i,j) = Q(:,i)'*A(:,j)
            V = V - R(i,j)*Q(:,i)
        end
        R(j,j) = norm(V,2)
        Q(:,j) = 1.0/R(j,j) * V
    end
endfunction
```

- Complexidade:
- O algoritmo pode falhar ?

Se $r_{jj} = \|v_j\| = 0$, o algoritmo falha.

$\Rightarrow$ Porém, isso só ocorre se $v_j = 0_m$ (vetor erro é identicamente nulo), o que significa que $A_j \in \text{span}\{q_1, q_2, \dots, q_{j-1}\} = \text{span}\{A_1, A_2, \dots, A_{j-1}\}$, contradizendo a hipótese de posto completo de A , $r(A) = n$.

$\Rightarrow$ Equivalentemente, neste caso, $p_j = A_j$, ou seja A_j é sua própria projeção em $\text{span}\{q_1, q_2, \dots, q_{j-1}\}$.

Vamos considerar que A não tenha posto completo: $r(A) < n$.

- Neste caso, devemos esperar que, para algum j , encontremos $v_j = 0_m$ e $r_{jj} = 0$.
- Eliminamos a coluna A_j do processo, pois ela não "adiciona posto" à A . $\mathcal{C}(A)$ não precisa de A_j (ou de um q_j associado a A_j para ser caracterizado).
- Assim, ao invés de obtermos uma nova coluna $q_j \in \mathcal{C}(A)$, linearmente independente com $\{q_1, \dots, q_{j-1}\}$, podemos "completar" a fatoração com qualquer coluna q_j ortogonal a $\{q_1, \dots, q_{j-1}\}$.
- Podemos estender a ideia acima de forma que Q tenha m colunas ortonormais e não apenas $r(A)$ colunas (ou $n = r(A)$ colunas quando o posto é completo) $\Rightarrow$ Fatoração QR completa.

porque Q tem as mesmas dimensões de A

- Veja que $Q \in \mathbb{R}^{m \times n}$ e $R \in \mathbb{R}^{n \times n}$.
- Q contém apenas colunas ortonormais que geram o espaço coluna de A .
- R contém, em suas colunas, os pesos que relacionam as combinações lineares de bases diferentes para o espaço coluna de A .

Porém, podemos expandir Q , adicionando a ela $m - r(A)$ novas colunas m dimensionais, que representam uma base para $\mathcal{N}(A^T)$ e introduzindo $m - r(A)$ linhas de zeros em R

permite tratar o caso em que A possui deficiência de posto e fornecer uma base para $\mathcal{N}(A^T)$

$A = QR$, porém com: $A \in \mathbb{R}^{m \times n}$, $Q \in \mathbb{R}^{m \times m}$, $R \in \mathbb{R}^{m \times n}$

$$Q = \left[\begin{array}{c|c|c|c|c|c|c} q_1 & q_2 & \cdots & q_{r(A)} & q_{r(A)+1} & \cdots & q_m \end{array} \right] \quad (2)$$

- $q_i : i = 1, \dots, r(A)$ fornecem base para $\mathcal{C}(A)$
- $q_j : j = r(A) + 1, \dots, m$ fornecem base $\mathcal{C}(A)^\perp = \mathcal{N}(A^T)$
- Completamos R com $m - r(A)$ linhas de zeros.

$$A = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 2 & 0 \\ -1 & 2 & 3 & -1 \\ 2 & 1 & 4 & 1 \end{bmatrix}.$$

Primeira iteração - $j = 1$:

$$A_1 = \begin{bmatrix} 1 \\ 0 \\ -1 \\ 2 \end{bmatrix}, q_1 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 0 \\ -1 \\ 2 \end{bmatrix}, r_{11} = \sqrt{6}.$$

Segunda iteração - $j = 2$:

$$A_2 = \begin{bmatrix} 0 \\ 1 \\ 2 \\ 1 \end{bmatrix}, q_1 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 0 \\ -1 \\ 2 \end{bmatrix}$$

Projeção: $p_2 = (q_1^T)A_2q_1 = 0q_1$ (ou seja: $q_1 \perp A_2$), $r_{12} = 0$

$$q_2 = \frac{\sqrt{6}}{6} \begin{bmatrix} 0 \\ 1 \\ 2 \\ 1 \end{bmatrix}, r_{22} = \sqrt{6}.$$

Terceira iteração - $j = 3$:

$$A_3 = \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \end{bmatrix}, \quad q_1 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 0 \\ -1 \\ 2 \end{bmatrix}, \quad q_2 = \frac{\sqrt{6}}{6} \begin{bmatrix} 0 \\ 1 \\ 2 \\ 1 \end{bmatrix}$$

Projeção: $p_3 = (q_1^T)A_3q_1 + (q_2^T)A_3q_2$

$$r_{13} = q_1^T A_3 = \sqrt{6}, \quad r_{23} = q_2^T A_3 = 2\sqrt{6}, \Rightarrow \quad p_3 = A_3$$

$$v_3 = 0, r_{33} = 0$$

Desta forma $A_3 \in \text{span}\{q_1, q_2\}$ e a matriz A não possui posto completo.

Em q_3 na fatoração, posteriormente, vamos armazenar uma coluna ortonormal, que seja ortogonal a $\mathcal{C}(A)$. Ou seja, ainda não determinamos q_3 . Adiamos, temporariamente este passo.

Quarta iteração - $j = 4$:

$$A_4 = \begin{bmatrix} 0 \\ 0 \\ -1 \\ 1 \end{bmatrix}, \quad q_1 = \frac{\sqrt{6}}{6} \begin{bmatrix} 1 \\ 0 \\ -1 \\ 2 \end{bmatrix}, \quad q_2 = \frac{\sqrt{6}}{6} \begin{bmatrix} 0 \\ 1 \\ 2 \\ 1 \end{bmatrix}$$

Projeção: $p_4 = (q_1^T)A_4q_1 + (q_2^T)A_4q_2 + 0q_3$

$$r_{14} = q_1^T A_4 = \frac{\sqrt{6}}{2}, \quad r_{24} = q_2^T A_4 = -\frac{\sqrt{6}}{6}, \quad r_{34} = 0.$$

$$p_4 = \begin{bmatrix} \frac{1}{2} \\ \frac{1}{6} \\ -\frac{5}{6} \\ -\frac{5}{6} \end{bmatrix}$$

$$\text{Erro: } v_4 = \begin{bmatrix} -\frac{1}{2} \\ \frac{1}{6} \\ -\frac{1}{6} \\ \frac{1}{6} \end{bmatrix}, \quad r_{44} = \frac{\sqrt{3}}{3}, \quad q_4 = \sqrt{3} \begin{bmatrix} -\frac{1}{2} \\ \frac{1}{6} \\ -\frac{1}{6} \\ \frac{1}{6} \end{bmatrix}$$

- Desejamos encontrar $q_3 \in \mathcal{N}(A^T)$.
- (apenas para facilitar as contas aqui....) multiplicando q_1, q_2, q_4 respectivamente por $\frac{6}{\sqrt{6}}, \frac{6}{\sqrt{6}}, \frac{6}{\sqrt{3}}$, resolvemos o sistema linear:

$$\begin{bmatrix} 1 & 0 & -1 & 2 \\ 0 & 1 & 2 & 1 \\ -3 & 1 & -1 & 1 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

- Após eliminação temos: $\begin{bmatrix} 1 & 0 & -1 & 2 \\ 0 & 1 & 2 & 1 \\ 0 & 0 & -6 & 6 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$

- Para resolvermos o sistema, arbitramos a variável livre y_4 , por exemplo em $y_4 = -1$ e resolvemos.

- Após eliminação temos:
$$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 1 & 2 \\ 0 & 0 & -6 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} 2 \\ 1 \\ 6 \end{bmatrix}$$

- Obtendo a solução $y = [1 \ 3 \ -1 \ -1]^T$

- Fazemos $q_3 = \frac{1}{\|y\|} y = \frac{\sqrt{3}}{6} [1 \ 3 \ -1 \ -1]^T$

- A terceira linha da matriz R é composta por zeros na fatoração.

- Para termos a estrutura que desejamos, fazemos um pivoteamento de colunas, trocando a 4a. com a 3a., de forma que as três primeiras entradas na diagonal de R sejam não nulas, uma vez que $r(A) = 3$.

Considere a matriz $A = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \\ 1 & 1 & 1 & 1 \\ 3 & 2 & 1 & 0 \end{bmatrix}$.

- Veja que $A_3 = 2A_2 - A_1$, $A_4 = 2A_3 - A_2$, $r(A) = 2$ e que, portanto, a matriz A tem deficiência de rank.
- A fatoração baseada puramente em Gram-Schmidt tem dificuldade em identificar o rank da matriz (fruto de erros numéricos).

```
-->[q,r] = Fatoracao_QR_Classica(A)
q =
  0.09245    0.5392919   -0.5465825   -0.5465825
  0.4622502   0.2927584   -0.370154    -0.370154
  0.8320503   0.046225    -0.2118872   -0.2118872
  0.09245    -0.0616334    0.0397829    0.0397829
  0.2773501   -0.7858253    0.7195517    0.7195517
r =
  10.816654   11.926054   13.035455   14.144855
  0.         1.6641006    3.3282012    4.9923018
  0.         0.         3.209D-14    -7.650426
  0.         0.         0.         7.650426
```

- 1 Assim que calculamos a coluna q_1 , projetamos as colunas $A_2, \dots, A_n$ em q_1 , calculamos os elementos $r_{1j} : j = 2, \dots, n$, calculamos a diferença (ou erro) $v_j = A_j - r_{1j}q_1$, que é armazenada no lugar de A_j , para as próximas iterações.

Repetimos a ideia para as demais colunas de Q que forem calculadas: uma vez que dispomos de q_i , **projetamos a diferença A_j** em q_i para todo $j = i + 1, \dots, n$ (podemos antecipar o cálculo dos r 's na linha pois os q 's são ortogonais).

Justificativa: As primeiras colunas de Q que calculamos carregam menos erros numéricos do que as últimas.

⇒ Esta ideia dá origem a uma modificação simples, porém bastante mais estável, da implementação anterior.

- 2 Pivoteamento de colunas.

Revisada sem ainda implementar o pivoteamento de colunas.'

```
function [Q,R] = Fatoracao_QR_Revisada(A)
// Nao inclui pivoteamento de colunas
// Assume rank completo
[m,n] = size(A)
R = zeros(n,n)
Q = zeros(m,n)
V = A
//printf("Rows %d, Columns %d \n ",m,n)
for i = 1:n
    R(i,i) = norm(V(:,i),2)
    Q(:,i) = V(:,i)/R(i,i)
    for j = (i+1):n
        R(i,j) = Q(:,i)'*V(:,j)
        V(:,j) = V(:,j) - R(i,j)*Q(:,i)
    end
end
endfunction
```

Fatoração $A = QR$ revisada (sem pivoteamento de colunas)

$$A = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \\ 1 & 1 & 1 & 1 \\ 3 & 2 & 1 & 0 \end{bmatrix}.$$

```
-->[Q,R] = Fatoracao_QR_Revisada(A)
```

```
Q =
```

```
0.09245    0.5392919 -0.1740118  0.2700975
0.4622502  0.2927584 -0.4524306 -0.8757263
0.8320503  0.046225  -0.843957  0.3894845
0.09245    -0.0616334 -0.0957065  0.0170553
0.2773501  -0.7858253 -0.2088141  0.0903422
```

```
R =
```

```
10.816654  11.926054  13.035455  14.144855
0.         1.6641006  3.3282012  4.9923018
0.         0.        6.380D-15  8.836D-15
0.         0.         0.        7.599D-16
```

```
-->[q,r] = Fatoracao_QR_Classica(A)
```

```
q =
```

```
0.09245    0.5392919 -0.5465825 -0.5465825
0.4622502  0.2927584 -0.370154  -0.370154
0.8320503  0.046225  -0.2118872 -0.2118872
0.09245    -0.0616334  0.0397829  0.0397829
0.2773501  -0.7858253  0.7195517  0.7195517
```

```
r =
```

```
10.816654  11.926054  13.035455  14.144855
0.         1.6641006  3.3282012  4.9923018
0.         0.        3.209D-14 -7.650426
0.         0.         0.        7.650426
```

Na implementação clássica:

- Na iteração j , referente à coluna A_j , calculamos a projeção $p_j = P_j A_j$, por meio do projetor P_j . Este projetor é calculado como a soma de $j - 1$ matrizes de rank 1.
- E na sequência, calculamos a diferença, $v_j = A_j - p_j$, por meio do projetor $(I - P_j)$. Esta transformação linear, dada por $I - P_j$, é uma operação de um único projetor de rank $m - (j - 1)$.

Na implementação revisada:

- Assim que q_i é conhecida, aplicamos o projetor no espaço ortogonal a $\text{span}\{q_i\}$ nas colunas $V(:, j)$ para $j > i$.
- Mais cedo este projetor sendo aplicado nas colunas $V(:, j)$ para $j > i$, menor o efeito acumulativo dos erros numéricos.
- Algebricamente, estamos calculando v_j como uma sequência de $j - 1$ projeções de rank $m - 1$.

- A fatoração $A = QR$ produzida pela **nossa implementação** (inocente, que assume posto completo), baseada exclusivamente na ideia de Gram-Schmidt, sem a revisão discutida, erradamente sugere que $r(A) = 3$.
- Um refinamento indispensável é o pivoteamento de colunas.
- Assim como na fatoração LU precisamos pivotar linhas para evitar erros numéricos, precisamos pivotar colunas na fatoração QR .
- Assim sendo, usaremos uma matriz de permutações P para representar as trocas de colunas $AP = QR$.

Resultados de algoritmos QR distintos

```
-->[q,r,P] = qr(A)
q =
-0.2666667    0.4777778    0.501608    0.6688727    0.0401987
-0.5333333    0.1222222    0.4967688   -0.6666392   -0.0971093
-0.8          -0.2333333   -0.503097    0.2268869   -0.0311653
-0.0666667   -0.0888889    0.0565821   -0.0650198    0.9900632
0.           -0.8333333    0.4952798    0.2291204   -0.0880759

r =
-15.   -10.2  -11.8      -13.4
0.    -3.6   -2.4      -1.2
0.     0.   -1.617D-15  -8.083D-16
0.     0.    0.        -2.465D-32
0.     0.    0.         0.

P =
0.    1.    0.    0.
0.    0.    1.    0.
0.    0.    0.    1.
1.    0.    0.    0.
```

```
-->[q,r] = Fatoracao_QR_Classica(A)
q =

0.09245    0.5392919   -0.5465825   -0.5465825
0.4622502    0.2927584   -0.370154   -0.370154
0.8320503    0.046225    -0.2118872   -0.2118872
0.09245    -0.0616334    0.0397829    0.0397829
0.2773501   -0.7858253    0.7195517    0.7195517

r =

10.816654    11.926054    13.035455    14.144855
0.           1.6641006    3.3282012    4.9923018
0.           0.         3.209D-14    -7.650426
0.           0.         0.         7.650426
```

- Na primeira iteração ($j = 1$)

A coluna de maior norma de A gera a primeira coluna q_1 de Q .

- Nas demais iterações $j \geq 2$

Consideramos as colunas $q_1, \dots, q_{j-1}$ geradas até aquela iteração e fazemos o seguinte:

- Seja $\mathcal{K}^j \subset \{1, 2, \dots, n\}$ o conjunto de índices de colunas de A que não foram empregadas para gerar colunas de Q até a iteração j .
- Para cada coluna $A_k : k \in \mathcal{K}^j$, calculamos p_k , a projeção da coluna A_k em $\text{span}\{q_1, \dots, q_{j-1}\}$ e, na sequência, calculamos a diferença $v_k = A_k - p_k$.
- A coluna $A_j : j \in \mathcal{K}^j$ que gera a coluna q_j de Q satisfaz:

$$j = \arg \max \|v_k\|_2 : k \in \mathcal{K}^j$$

Atenção: ilustramos a introdução do pivoteamento na implementação clássica pois aqui, vamos usar aritmética de precisão infinita.

$$A = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \\ 1 & 1 & 1 & 1 \\ 3 & 2 & 1 & 0 \end{bmatrix}.$$

Primeira coluna:

- A coluna de maior norma Euclideana é A_4 , com $\|A_4\| = 15$.
- $r_{11} = 15$, $pivot(1) = 4$, $pivot(4) = 1$

- $q_1 = \frac{1}{15} \begin{bmatrix} 4 \\ 8 \\ 12 \\ 1 \end{bmatrix}$

Segunda coluna: $j = 2$

- Colunas candidatas: $\begin{bmatrix} A_1 & A_2 & A_3 \\ \hline 1 & 2 & 3 \\ 5 & 6 & 7 \\ 9 & 10 & 11 \\ 1 & 1 & 1 \\ 3 & 2 & 1 \end{bmatrix}, q_1 = \frac{1}{15} \begin{bmatrix} 4 \\ 8 \\ 12 \\ 1 \\ 0 \end{bmatrix}$
- Calculamos a projeção p_k^{j-1} de cada coluna candidata $A_k : k \in \{1, 2, 3\}$ em $\text{span}\{q_1\}$.
- Calculamos a diferença $v_k^{j-1} = A_k - p_k^{j-1} : k \in \{1, 2, 3\}$
- Calculamos $\|v_k^{j-1}\| : k \in \{1, 2, 3\}$
- Escolhemos a coluna A_k que maximiza a norma $\|v_k^{j-1}\|$

Segunda coluna: $j = 2$

- Colunas candidatas:
$$\begin{bmatrix} A_1 & A_2 & A_3 \\ \hline 1 & 2 & 3 \\ 5 & 6 & 7 \\ 9 & 10 & 11 \\ 1 & 1 & 1 \\ 3 & 2 & 1 \end{bmatrix}, q_1 = \frac{1}{15} \begin{bmatrix} 4 \\ 8 \\ 12 \\ 1 \\ 0 \end{bmatrix}$$

- Produtos internos: $q_1^T A_1 = \frac{153}{15}$, $q_1^T A_2 = \frac{177}{15}$, $q_1^T A_3 = \frac{201}{15}$.

- Projeções: $p_1^1 = \frac{153}{15} q_1$, $p_2^1 = \frac{177}{15} q_1$, $p_3^1 = \frac{201}{15} q_1$

- Diferenças: $v_1^1 = A_1 - \frac{153}{15} q_1$, $v_2^1 = A_2 - \frac{177}{15} q_1$, $v_3^1 = A_3 - \frac{201}{15} q_1$

Segunda coluna: $j = 2$

$$\bullet v_1^1 = \frac{1}{225} \begin{bmatrix} -387 \\ -99 \\ 189 \\ 72 \\ 675 \end{bmatrix}, v_2^1 = \frac{1}{225} \begin{bmatrix} -162 \\ 126 \\ 414 \\ 72 \\ 450 \end{bmatrix}, v_3^1 = \frac{1}{225} \begin{bmatrix} 63 \\ 351 \\ 639 \\ 72 \\ 225 \end{bmatrix}$$

$$\bullet \|v_1^1\| = \frac{810}{225}, \|v_2^1\| < \frac{649}{225}, \|v_3^1\| < \frac{769}{225}$$

$$\bullet \text{Logo, } q_2 \text{ vem de } v_1^1, r_{22} = \frac{810}{225} = 3.6 \text{ (pivot}(2) = 1)$$

$$\bullet q_2 = v_1^1 : \left(\frac{810}{225}\right) = \frac{1}{810} \begin{bmatrix} -387 \\ -99 \\ 189 \\ 72 \\ 675 \end{bmatrix}$$

$$\bullet \text{Como } q_2 \text{ veio de } A_1, r_{12} = q_1^T A_1 = \frac{153}{15} = 10.2$$

Terceira coluna: $j = 3$

$$\bullet \text{ Candidatas: } \begin{bmatrix} A_2 & A_3 \\ 2 & 3 \\ 6 & 7 \\ 10 & 11 \\ 1 & 1 \\ 2 & 1 \end{bmatrix}, q_1 = \frac{1}{15} \begin{bmatrix} 4 \\ 8 \\ 12 \\ 1 \\ 0 \end{bmatrix}, q_2 = \frac{1}{810} \begin{bmatrix} -387 \\ -99 \\ 189 \\ 72 \\ 675 \end{bmatrix}$$

$$\bullet \text{ Produtos internos já calculados: } q_1^T A_2 = \frac{177}{15}, q_1^T A_3 = \frac{201}{15}.$$

$$\bullet \text{ Novos produtos internos: } q_2^T A_2 = \frac{12}{5}, q_2^T A_3 = \frac{6}{5}$$

$$\bullet \text{ Projeções: } p_2^2 = (q_1^T A_2)q_1 + (q_2^T A_2)q_2 = \frac{177}{15}q_1 + \frac{12}{5}q_2, \\ p_3^2 = (q_1^T A_3)q_1 + (q_2^T A_3)q_2 = \frac{201}{15}q_1 + \frac{6}{5}q_2$$

$$\bullet \text{ Diferenças: } v_2^2 = A_2 - p_2^2 \text{ e } v_3^2 = A_3 - p_3^2$$

Terceira coluna: $j = 3$

- Projeções: $p_2^2 = (q_1^T A_2)q_1 + (q_2^T A_2)q_2 = \frac{177}{15}q_1 + \frac{12}{5}q_2$,
 $p_3^2 = (q_1^T A_3)q_1 + (q_2^T A_3)q_2 = \frac{201}{15}q_1 + \frac{6}{5}q_2$

- $p_2^2 = \begin{bmatrix} 2 \\ 6 \\ 10 \\ 1 \\ 2 \end{bmatrix} = A_2 \rightarrow v_2^2 = 0$

- $p_3^2 = \begin{bmatrix} 3 \\ 7 \\ 11 \\ 1 \\ 1 \end{bmatrix} = A_3 \rightarrow v_3^2 = 0$

- Neste momento, sabemos que o $r(A) = 2$ e concluímos a fatoração reduzida.
- As demais colunas na fatoração completa devem ser resolvidas via eliminação.

- A primeira e segunda colunas de Q vieram respectivamente da quarta e primeira colunas de A .
- A terceira e quarta colunas de Q não foram calculadas.
- Veja que $r(A) = 2$ ($\#$ elementos não nulos na diagonal de R).
- As linhas de índice $\geq (r(A) + 1)$ de R (tanto na fatoração completa quanto na reduzida) serão nulas.

$$A = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \\ 1 & 1 & 1 & 1 \\ 3 & 2 & 1 & 0 \end{bmatrix} \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{bmatrix} =$$

$$\begin{bmatrix} | & | & | & | \\ q_1 & q_2 & q_3 & q_4 \\ | & | & | & | \end{bmatrix} \begin{bmatrix} 15 & \frac{153}{15} & \frac{177}{15} & \frac{201}{15} \\ 0 & 3.6 & \frac{12}{5} & \frac{6}{5} \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}.$$

- Na fatoração completa teríamos uma quinta coluna $q_5 \in \mathcal{N}(A^T)$ e $R : 5 \times 4$, com 3 linhas de zeros.

Pivoteamento implementado na versão revisada. Ainda assume rank completo, mas detecta rank numérico.

```
function [Q,R,pivot] = Fatoracao_QR_TrocaColunas(A)
    [m,n] = size(A)
    nainf = norm(A,'inf'); eps = 1.0E-14
    pivot = zeros(n); R = zeros(n,n); Q = zeros(m,n)
    posto = n;
    for i=1:n
        pivot(i) = i
    end
    V = A
    for i = 1:n
        [p,nmax] = DeterminaNormaMaxima(V,i,n)
        if (p <> i) then
            [R,V,pivot] = TrocaConteudoColunas(i,p,R,V,pivot)
        end
        R(i,i) = nmax
        if ((nmax < eps * nainf) & (posto == n)) then
            posto = i-1
        end
        Q(:,i) = V(:,i)/R(i,i)
        for j = (i+1):n
            R(i,j) = Q(:,i)'*V(:,j)
            V(:,j) = V(:,j) - R(i,j)*Q(:,i)
        end
    end
    printf("Rank numérico detectado: %d \n",posto)
endfunction
```

Fatoração $A = QR$ com pivoteamento de colunas

$$A = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \\ 1 & 1 & 1 & 1 \\ 3 & 2 & 1 & 0 \end{bmatrix}.$$

```
-->[Q,R] = Fatoracao_QR_Revisada(A)
```

```
Q =  
  
    0.09245    0.5392919   -0.1740118    0.2700975  
    0.4622502    0.2927584   -0.4524306   -0.8757263  
    0.8320503    0.046225   -0.843957    0.3894845  
    0.09245   -0.0616334   -0.0957065    0.0170553  
    0.2773501   -0.7858253   -0.2088141    0.0903422  
R =  
    10.816654    11.926054    13.035455    14.144855  
    0.          1.6641006    3.3282012    4.9923018  
    0.          0.          6.380D-15    8.836D-15  
    0.          0.          0.          7.599D-16
```

```
[Q,R,pivot] = Fatoracao_QR_TrocaColunas(A)
```

```
Rank numérico detectado: 2
```

```
Q =  
    0.2666667   -0.4777778   -0.281048    0.0586473  
    0.5333333   -0.1222222   -0.562096    0.6266858  
    0.8         0.2333333   -0.7728819   -0.4936518  
    0.0666667    0.0888889   -0.0878275    0.1456751  
    0.          0.8333333    0.          0.5821615  
R =  
    15.    10.2    11.8        13.4  
    0.     3.6     2.4         1.2  
    0.     0.     1.580D-15    4.746D-16  
    0.     0.     0.          3.814D-16  
pivot =  
    4.  
    1.  
    2.  
    3.
```

- Vamos assumir aqui que a matriz a ser fatorada possui posto completo, $r(A) = n$.
- Ao final do processo de fatoração, devemos ter $I - Q^T Q = 0$.
- Uma medida do efeito de erros numéricos pode ser obtida calculando-se $\|I - Q^T Q\|_2$.
- **Idealmente** $\|I - Q^T Q\|_2 \approx c\epsilon$, onde c é uma constante pequena e ϵ é a precisão da máquina.

Vamos conduzir o seguinte experimento numérico com a fatoração de uma matriz de Vandermonde retangular:

- Vamos fatorar $V = QR$ para uma matriz de Vandermonde V , retangular $m \times n$, para diversos valores de m, n , usando os três algoritmos que discutimos aqui, além de uma implementação mais sofisticada, existente nos pacotes de Álgebra Linear Numérica, como Scilab, MATLAB, NumPy.
- Os elementos da matriz de Vandermonde considerada são

$$v_{ij} = \left(\frac{j}{n}\right)^{i-1}.$$

- Para cada algoritmo, avaliamos o indicador $\|I - Q^T Q\|_2$ obtido com a matriz Q produzido pelo algoritmo.

A tabela apresenta valores para $\|I - Q^T Q\|_2$ para quatro implementações distintas da fatoração QR de V .

m	n	$\kappa(V)$	Algoritmo empregado			
			QR Clássico	QR Rev	QR Rev + Troca	qr Scilab
6	4	1.066D+02	5.243D-15	4.696D-15	7.226D-15	9.174D-16
9	6	2.752D+03	8.253D-11	1.283D-13	1.363D-13	6.753D-16
12	8	7.280D+04	0.0000026	3.274D-12	2.468D-12	9.491D-16
15	10	1.952D+06	0.1265365	8.151D-11	3.466D-11	6.636D-16
18	12	5.280D+07	2.6409387	1.037D-09	1.669D-09	8.429D-16
25	20	3.243D+14	11.387547	0.0079543	0.0083214	1.314D-15

- $\kappa_p(V)$ é o número de condição de uma matriz retangular, $\kappa := \frac{\max_{x \neq 0} \|Vx\|_p}{\min_{x \neq 0} \|Vx\|_p}$
- O método revisado possui $\|I - Q^T Q\|_2 \approx k_2(V)\epsilon$.
- $\epsilon \approx 1.11 \times 10^{-16}$
- O algoritmo implementado no Scilab utiliza ortogonalização por *refletores de Householder*, uma técnica a ser discutida na sequência.

Se as colunas de Q não forem suficientemente ortogonais, podemos reortogonalizar Q . No exemplo abaixo, isso é feito *a posteriori*, apenas para ilustrar o efeito do processo. Mas na prática, a segunda (ou as múltiplas) ortogonalizaç(ões) é (são) feita(s) internamente.

```
function [Q,R] = Fatoracao_Revisada_Reortogonalizacao(A)
    [m,n] = size(A)
    [Q,R] = Fatoracao_QR_Revisada(A)
    n2 = norm(eye(n,n)-Q'*Q,2)
    printf("%4.3E \n",n2)
    while (n2 > 100*%eps)
        [Qn,Rn] = Fatoracao_QR_Revisada(Q)
        n2 = norm(eye(n,n)-Qn'*Qn,2)
        printf("%4.3E \n",n2)
        R = Rn*R
    end
endfunction
```

Considerando a fatoração de V de ordem 25×20 anterior:

```
-->V = GeraVandermondeMod(25,20);  
  
-->[Q,R] = Fatoracao_Revisada_Reortogonalizacao(V);  
7.954E-03  
4.572E-16  
  
-->norm(V-Q*R,'inf')  
ans =  
  
1.634D-12
```

- 1 É uma técnica que usa o conceito de *refletor* (de Householder).
- 2 Dentre outros propósitos, é empregada para se produzir uma fatoração $A = QR$ bastante estável.
- 3 Também reúne ideias importantes para o cálculo de autovalores e autovetores, podendo ser empregada em etapas de algoritmos para a decomposição em valores singulares de A .

- Na primeira iteração de Gram-Schmidt (revisada), inicializamos $v_k^1 \leftarrow A_k : k = 1, \dots, n$, e ortogonalizamos a primeira:

$$\left[\begin{array}{c|c|c|c|c} v_1^1 & v_2^1 & \cdots & v_n^1 \end{array} \right] \left[\begin{array}{ccccc} \frac{1}{r_{11}} & \frac{-r_{12}}{r_{11}} & \frac{-r_{13}}{r_{11}} & \cdots & \frac{-r_{1n}}{r_{11}} \\ & 1 & & & \\ & & 1 & & \\ & & & \ddots & \\ & & & & 1 \end{array} \right] = \left[\begin{array}{c|c|c|c|c} q_1 & v_2^2 & \cdots & v_n^2 \end{array} \right] \quad (3)$$

lembrando que $v_k^i = A_k - \sum_{l=1}^{i-1} (q_l^T A_k) q_l$

- Na segunda iteração:

$$\left[\begin{array}{c|c|c|c|c} q_1 & v_2^2 & v_3^2 & \cdots & v_n^2 \end{array} \right] \left[\begin{array}{ccccc} 1 & & & & \\ & \frac{1}{r_{22}} & \frac{-r_{23}}{r_{22}} & \cdots & \frac{-r_{2n}}{r_{22}} \\ & & 1 & & \\ & & & \ddots & \\ & & & & 1 \end{array} \right] = \left[\begin{array}{c|c|c|c|c} q_1 & q_2 & v_3^3 & \cdots & v_n^3 \end{array} \right] \quad (4)$$

- Ou seja, a cada iteração $i = 1, \dots, n$ multiplicamos a matriz (parcialmente) ortogonalizada que dispunhamos na iteração anterior, por uma matriz triangular superior R_i .
- Ao final de n iterações:

$$AR_1R_2 \dots R_n = Q$$

- O produto $R_1R_2 \dots R_n$ é também triangular superior, não singular (assumindo $r(A) = n$).
- O fator R na fatoração $A = QR$ satisfaz a relação:

$$R^{-1} = R_1R_2 \dots R_n$$

- Ou seja, Gram-Schmidt faz uma ortogonalização triangular, isto é, ortogonaliza as colunas de A , por meio da multiplicação de A por matrizes R_i triangulares superiores, convenientemente escolhidas.

- **Gram-Schmidt faz ortogonalização triangular:** usa matrizes triangulares superiores, multiplicando à direita de A , para obter uma matriz Q ortogonal.
- **Householder faz uma triangularização ortogonal:** usa matrizes ortogonais (construídas por meio de refletores), pré-multiplicando A , para transformar A em uma matriz triangular superior.

- A ideia é **construir** matrizes ortogonais Q_k (unitárias, no caso complexo) tais que $Q_n Q_{n-1} \dots Q_2 Q_1 A = R$, onde R é uma matriz triangular superior.
- **Recordando:** o produto de matrizes ortogonais é uma matriz ortogonal, portanto $A = Q_1^T \dots Q_n^T R$ é uma fatoração QR de A (ortogonal por triangular superior).
- Veja o efeito desejado de $Q_1, Q_2, Q_3, \dots$

$$\begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \xrightarrow{Q_1} \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix} \xrightarrow{Q_2} \begin{bmatrix} x & x & x \\ x & x & \\ 0 & x & \\ 0 & x & \\ 0 & x & \end{bmatrix} \xrightarrow{Q_3} \begin{bmatrix} x & x & x \\ & x & x \\ & x & \\ & & 0 \\ & & 0 \end{bmatrix}$$

- A k -ésima matriz Q_k é escolhida para introduzir zeros na k -ésima coluna de $Q_{k-1} \dots Q_1 A$, preservando os zeros gerados nas colunas de índice igual ou inferior a $k - 1$, nas iterações anteriores.

$$\begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \xrightarrow{Q_1} \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix} \xrightarrow{Q_2} \begin{bmatrix} x & x & x \\ & x & x \\ & 0 & x \\ & 0 & x \\ & 0 & x \end{bmatrix} \xrightarrow{Q_3} \begin{bmatrix} x & x & x \\ & x & x \\ & & x \\ & & 0 \\ & & 0 \end{bmatrix}$$

Refletor de Householder

Dado um vetor $v \in \mathbb{R}^n$ e $u = \frac{v}{\|v\|}$ sua normalização, a matriz

$$F = I - \frac{2}{\|v\|^2} vv^T = I - 2uu^T$$

é chamada de refletor de Householder.

Propriedades de F :


- Simétrica.
- Ortogonal:

$$\begin{aligned} (I - 2uu^T)^T(I - 2uu^T) &= I - 4uu^T + (2uu^T)^T(2uu^T) \\ &= I - 4uu^T + 4uu^T uu^T \\ &= I \end{aligned}$$

- Não singular.

Dados dois vetores $a, r \in \mathbb{R}^n$ tais que $\|a\| = \|r\|$ e $v = a - r$, a matriz $F = I - 2 \frac{vv^T}{\|v\|^2}$ aplicada em a satisfaz:

$$Fa = r$$



$$\begin{aligned}
Fa &= \left(I - 2 \frac{(a-r)(a-r)^T}{(a-r)^T(a-r)} \right) a \\
&= a - 2 \frac{(a-r)(a^T a - r^T a)}{(a-r)^T(a-r)} \\
&= a - 2 \frac{(a-r)(a^T a - r^T a)}{a^T a - 2r^T a + r^T r} \\
&= a - 2 \frac{(a-r)(a^T a - r^T a)}{2a^T a - 2r^T a} \\
&= a - 2 \frac{(a-r)(a^T a - r^T a)}{2(a^T a - r^T a)} \\
&= r
\end{aligned}$$

Consequência: como $F = F^T$ e $F^T F = I$, temos que $F^T(Fa) = F^T r = Fr$, logo $a = Fr$ (reflexão).

- **Invariante:** No início da iteração k , há um bloco de vetores de zeros nas colunas $k - 1$ anteriores.
- Na iteração k , a aplicação de Q_k em $Q_{k-1} \dots Q_1 A$, combina as linhas de $Q_{k-1} \dots Q_1 A$. A combinação linear das entradas zero permanece zero.
- Para se garantir esta propriedade (preservar as entradas zero já criadas nas colunas de índice $k - 1$ ou menor), escolhemos a matriz Q_k ortogonal (ou unitária), cujo particionamento em blocos é:

$$Q_k = \begin{bmatrix} I & 0 \\ 0 & F \end{bmatrix},$$

onde I é a matriz identidade de ordem $k - 1$ e F é uma matriz ortogonal de ordem $m - (k - 1)$.

- O refletor F é responsável por produzir zeros nas posições corretas da coluna k .


- Vamos assumir que no início da iteração k , as entradas nas linhas $k, k+1, \dots, m$ da coluna k de $Q_{k-1} \dots Q_1 A$ sejam representadas pelo vetor $x \in \mathbb{R}^{m-(k-1)}$.
- O refletor F aplicado em x deve produzir a transformação linear:

$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_{m-(k-1)} \end{bmatrix} \xrightarrow{F} Fx = \begin{bmatrix} \|x\| \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \|x\| e_1$$

onde e_1 é um vetor de zeros, exceto pela primeira posição que é 1.

Interpretação geométrica da ação de F em x

- Na forma como definimos, F reflete o espaço $\mathbb{R}^{m-(k-1)}$ em torno do hiperplano H_1 .
- O vetor $v = \|x\|e_1 - x$ é perpendicular ao hiperplano H .
- Porém, há mais de uma escolha para F . Veja o subespaço H_2 .



Vamos considerar a figura anterior e a escolha de F tal que

$$Fx = +\|x\|e_1.$$

- O vetor $v = +\|x\|e_1 - x$ é perpendicular ao subespaço H_1 (H_1 é um hiperplano que passa pela origem, por isso é um subespaço).
- Veja que, a partir de x , o ponto em que o vetor v intercepta H_1 está na metade do segmento até o ponto Fx , resultado da transformação linear por x .
- Sabemos que se desejamos projetar um vetor qualquer y em $\text{span}\{v\}^\perp$ (isto é, no subespaço definido por H_1) precisamos aplicar o projetor

$$P = \left(I - \frac{vv^T}{v^T v} \right),$$

em y , uma vez que o projetor $\frac{vv^T}{v^T v}$ projeta y em $\text{span}\{v\}$.

Vamos considerar a figura anterior e a escolha de F tal que

$$Fx = +\|x\|e_1.$$

- Se aplicarmos o deslocamento $\left(I - \frac{vv^T}{v^Tv}\right)$ em x , obtemos o ponto $\left(I - \frac{vv^T}{v^Tv}\right)x$ que é sua projeção em H_1 e está na metade do segmento que nos leva até o ponto $+\|x\|e_1$ desejado.
- Portanto, para obtermos o ponto $Fx = +\|x\|e_1$, devemos aplicar em x a matriz $\left(I - 2\frac{vv^T}{v^Tv}\right)$.
- Por esta razão, o refletor de Householder é $F = \left(I - 2\frac{vv^T}{v^Tv}\right)$.
- Já mostramos que $F^T F = I$. Logo $Q_k^T Q_k = I$.

$$A = \begin{bmatrix} -4 & 1 & 1 \\ 2 & 1 & -1 \\ 4 & 1 & 1 \end{bmatrix}.$$

Primeira iteração:

- $x = \begin{bmatrix} -4 & 2 & 4 \end{bmatrix}^T$, $\|x\| = 6$.

- $v^T = \begin{bmatrix} 6 & 0 & 0 \end{bmatrix}^T - \begin{bmatrix} -4 & 2 & 4 \end{bmatrix}^T = \begin{bmatrix} 10 & -2 & -4 \end{bmatrix}^T$,
 $v^T v = 120$.

- $F = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} - \frac{2}{120} \begin{bmatrix} 10 \\ -2 \\ -4 \end{bmatrix} \begin{bmatrix} 10 & -2 & -4 \end{bmatrix}$

$$F = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} - \frac{2}{120} \begin{bmatrix} 100 & -20 & -40 \\ -20 & 4 & 8 \\ -40 & 8 & 16 \end{bmatrix}$$

$$F = \begin{bmatrix} -2/3 & 1/3 & 2/3 \\ 1/3 & 14/15 & -2/15 \\ 2/3 & -2/15 & 11/15 \end{bmatrix}$$

Primeira iteração (continua):

$$\bullet FA = \begin{bmatrix} -2/3 & 1/3 & 2/3 \\ 1/3 & 14/15 & -2/15 \\ 2/3 & -2/15 & 11/15 \end{bmatrix} \begin{bmatrix} -4 & 1 & 1 \\ 2 & 1 & -1 \\ 4 & 1 & 1 \end{bmatrix} =$$
$$\begin{bmatrix} 6 & 1/3 & -1/3 \\ 0 & 17/15 & -11/15 \\ 0 & 19/15 & 23/15 \end{bmatrix}$$

- Para a primeira iteração, temos $Q_1 = F$.

Segunda iteração:

- $Q_1 A = \begin{bmatrix} 6 & 1/3 & -1/3 \\ 0 & 17/15 & -11/15 \\ 0 & 19/15 & 23/15 \end{bmatrix}$
- Q_2 tem a forma $\left[\begin{array}{c|c} 1 & 0 \\ \hline 0 & F_2 \end{array} \right]$, onde $F_2 \in \mathbb{R}^{2 \times 2}$ é o segundo refletor.
- F_2 será contruído a partir de $x = \begin{bmatrix} 17/15 & 19/15 \end{bmatrix}^T$,
 $\|x\| = \frac{\sqrt{26}}{3}$.
- $v = \frac{\sqrt{26}}{3} \begin{bmatrix} 1 & 0 \end{bmatrix}^T - \begin{bmatrix} 17/15 & 19/15 \end{bmatrix}^T =$
 $\begin{bmatrix} \frac{5\sqrt{26}-17}{15} & -\frac{19}{15} \end{bmatrix}^T$, $v^T v \approx 1.9251853$.
- $F_2 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - 2/1.9251853 \begin{bmatrix} \frac{5\sqrt{26}-17}{15} \\ -\frac{19}{15} \end{bmatrix} \begin{bmatrix} \frac{5\sqrt{26}-17}{15} & -\frac{19}{15} \end{bmatrix}$
 $F_2 = \begin{bmatrix} 0.6667949 & 0.7452413 \\ 0.7452413 & -0.6667949 \end{bmatrix}$

Segunda iteração (continua):


- $Q_2 Q_1 A = R = \begin{bmatrix} 6 & 1/3 & -1/3 \\ 0 & 1.6996732 & 0.6537205 \\ 0 & 0 & -1.5689291 \end{bmatrix}$

- $Q_2 Q_1 = \begin{bmatrix} -0.6666667 & 0.3333333 & 0.6666667 \\ 0.7190925 & 0.5229764 & 0.4576043 \\ -0.1961161 & 0.7844645 & -0.5883484 \end{bmatrix}$

- Fatoração QR resultante: $A = (Q_2 Q_1)^T R$

- Veja que não dispomos explicitamente do fator $(Q_2 Q_1)^T$.

- e $A \in \mathbb{C}^{m \times n}$, temos inúmeras escolhas de pontos de reflexão: pode ser qualquer $z\|x\|e_1$ para um complexo $z \in \mathbb{C}$, $|z| = 1$.
- No caso de $A \in \mathbb{R}^{m \times n}$, temos duas escolhas. Veja abaixo:



- Para aumentar a estabilidade numérica, devemos escolher o ponto de reflexão que promove o máximo deslocamento, isto é, $z = -\text{sinal}(x_1)$ ($\text{sinal}(x_1)$ retorna -1 se $x_1 < 0$ ou 1, cc).
- Na figura: escolhemos $-\|x\|e_1$ e a direção $v = -\|x\|e_1 - x$.

- Opção 1: $v = \|x\|e_1 - x$
- Opção 2: $v = -\|x\|e_1 - x$
- A escolha mais estável: $v = -\text{sign}(x_1)\|x\|e_1 - x$, que para efeito do cálculo de F é equivalente a $\text{sign}(x_1)\|x\| + x$

```
function [Q,R] = QR_Householder(A)
    [m,n] = size(A)
    R = A
    P = eye(m,m)
    for k = 1:n
        x = R(k:m,k)

        vk = sign(x(1))*norm(x,2) * eye(m-k+1,1) + x
        vk = 1.0 / norm(vk,2) * vk

        R(k:m,k:n) = R(k:m,k:n)-2.0*vk*(vk'*R(k:m,k:n))

        Pa = eye(m,m)
        Pa(k:m,k:m) = eye(m-k+1,m-k+1)-2.0*vk*vk'*Pa(k:m,k:m)
        P = Pa*P
    end
    Q = P'
endfunction
```

- ① Vimos que para resolver

$$\min \|Ax - b\|,$$

podemos formular e resolver o sistema de equações normais:

$$A^T A \hat{x} = A^T b$$

que nos fornece o vetor $\hat{x}$ tal que $p = A\hat{x}$ está em $\mathcal{C}(A)$ e $\hat{x}$ é o vetor de parâmetros que melhor explica os dados.

- ② A matriz $A^T A$ é usualmente malcondicionada e seu cálculo deve ser evitado.
- ③ Podemos usar a fatoração QR de A para resolver o problema, sem explicitamente calcular $A^T A$.

Supondo que a fatoração $A = QR$ (reduzida, R é quadrada de ordem $r(A)$) seja disponível e que $P = A(A^T A)^{-1} A^T$ denote o projetor ortogonal em $\mathcal{C}(A)$. Assumimos que as colunas ld de A foram removidas.

$$\begin{aligned} P &= A(A^T A)^{-1} A^T \\ &= (QR)(R^T Q^T QR)^{-1} (R^T Q^T) \\ &= (QR)(R^T R)^{-1} (R^T Q^T) \\ &= (QR)(R^{-1} R^{-T})(R^T Q^T) \\ &= QQ^T \end{aligned}$$

- ① Com o projetor calculamos $p = Pb$.
- ② Como $p \in \mathcal{C}(A)$, o sistema linear $Ax = p$ possui uma solução.
- ③ Combinando temos: $Ax = Pb \rightarrow QRx = Pb = QQ^T b$.
- ④ Então, mais precisamente:
 - ① Calculamos a fatoração $A = QR$ (reduzida), calculamos o vetor $Q^T b$ (se dispomos de Q explícita)
 - ② Ou, se não desejamos armazenar Q explicitamente (alguma implementação de Householder que por escolha não armazene Q), fatoramos $[A|b]$ na forma QR . Ao final, obtemos a matriz $[R|Q^T b]$.
 - ③ Resolvemos o sistema triangular superior $Rx = Q^T b$, para obter o vetor de parâmetros ótimo x da regressão linear.

$$b = \alpha x^\beta \rightarrow \ln b = \ln \alpha + \beta \ln x.$$

Velocidade (m/s)	10	20	30	40	50	60	70	80
Força (N)	25	70	380	550	610	1220	830	1450

A matriz $[A|b]$ correspondente à linearização é:

$Ab =$

1.	2.3025851	3.2188758
1.	2.9957323	4.2484952
1.	3.4011974	5.9401713
1.	3.6888795	6.3099183
1.	3.912023	6.413459
1.	4.0943446	7.1066061
1.	4.2484952	6.7214257
1.	4.3820266	7.2793188

- Resolvendo via Fatoração de Householder.
- Fatoramos a matriz $[A|b]$ acima, obtendo Q, R .
- A terceira coluna da matriz R fornecida é, na verdade $Q^T b$.
- Resolvemos $Rx = Q^T b$ e obtemos $\ln(\alpha), \beta$.

```
[Q,R] = QR_Householder(Ab);  
x = inv(R(1:2,1:2))*R(1:2,3)  
x =  
    -1.294126  
     1.9841763
```

Então $\alpha = e^{-1.294126} = 0.2741373$