

Decomposição QR para resolver Problemas de Quadrados Mínimos



Instituto de Matemática
Pura e Aplicada

Dyckson Ternoski¹
Marina Sayuri Vieira²
Monique Baptista Fragozo³
Otávio Dittrich Moreira⁴

Orientador: Prof. Dr. Abel Soares Siqueira⁵

Universidade Federal do Paraná

¹dycksonternoski@hotmail.com, ²marinasayuril6@gmail.com, ³mbaptistafragozo@gmail.com,
⁴otaviodittrich@gmail.com, ⁵abelsiqueira@ufpr.br



Resumo

Com o objetivo de otimizar a resolução do problema de quadrados mínimos, neste trabalho implementamos na linguagem Julia a fatoração QR por Gram-Schmidt e por Rotação de Givens, comparando os dois métodos a partir da memória e tempo gastos.

1. O Problema de Quadrados Mínimos

Um dos problemas mais importantes em aplicações matemáticas é a resolução de sistemas lineares da forma:

$$Ax = b \quad (1)$$

onde $A \in \mathbb{R}^{n \times n}$ e $b \in \mathbb{R}^m$. Quando $m > n$, temos um sistema com mais equações do que incógnitas e (1) pode não ter solução. Nesse caso, a melhor solução é resolver o Problema de Quadrados Mínimos: $\min_{x \in \mathbb{R}^n} \|Ax - b\|_2^2$.

Isso envolve resolver o sistema: $A^t Ax = A^t b$, o qual possui solução única $x = (A^t A)^{-1} A^t b$ sempre que A tem vetores coluna L.I. Porém, a inversão de matrizes possui um gasto computacional alto. Para isso, utilizaremos a decomposição QR.

2. Decomposição QR

Definição 1. A decomposição QR de uma matriz A é o par de matrizes Q e R , ortogonal e triangular superior, respectivamente, satisfazendo $A = QR$.

Proposição 1. Se Q é uma matriz ortogonal então Q preserva a norma.
De fato,

$$\|Qv\|_2^2 = (Qv)^t Qv = v^t Q^t Qv = v^t v = \|v\|_2^2$$

2.1 Por Gram-Schmidt

Teorema 1. Seja $A \in \mathbb{R}^{n \times n}$ com colunas L.I. Podemos usar o processo de Gram-Schmidt nas colunas a_1, a_2, \dots, a_n da matriz A e normalizá-las, obtendo elementos q_1, q_2, \dots, q_n para encontrar a decomposição QR, sendo: $Q = (q_1 q_2 \dots q_n)$ e $R = Q^t A$.

Abaixo o algoritmo para o cálculo da decomposição QR por Gram-Schmidt.

Algoritmo 1: QR POR GRAM-SCHMIDT

```

Entrada:  $A \in \mathbb{R}^{m \times n}$   $A = (a_1, a_2, \dots, a_n)$ ;  $ntol = 1e-12$ 
Saída: Q,R Decomposição QR de A
1 início
2    $q_1 \leftarrow \frac{a_1}{\|a_1\|}$ 
3   para  $i$  de 2 à  $m$  faça
4      $w_i \leftarrow a_i - \sum_{j=1}^{i-1} \langle q_j, a_i \rangle q_j$ 
5     se  $\|w_i\| \leq ntol$  então
6       Erro: Norma de  $w_i$  muito próxima de 0
7     fim
8      $q_i \leftarrow \frac{w_i}{\|w_i\|}$ 
9   fim
10   $Q \leftarrow (q_1, q_2, \dots, q_n)$ 
11   $R = Q^t A$ 
12  retorna Q, R
13 fim

```

2.2 Por Rotação de Givens

Teorema 2. Se A é uma matriz que satisfaz $\text{posto}(A) = n$, então existem matrizes de rotação Q_1, Q_2, \dots, Q_n tais que: $Q_1 Q_2 \dots Q_n A = R$, sendo R triangular superior. Portanto, se $Q = Q_n^t Q_{n-1}^t \dots Q_1^t$, então: $A = QR$ é uma decomposição QR de A .

A seguir o algoritmo desenvolvido para o cálculo da decomposição QR por Rotação de Givens.

Algoritmo 2: QR POR ROTAÇÕES DE GIVENS

```

Entrada:  $A \in \mathbb{R}^{m \times n}$   $A = (a_1, a_2, \dots, a_n)^t$ 
Saída: Q,R Decomposição QR de A
1 início
2    $Q = (q_1, q_2, \dots, q_n)^t = \text{Identidade } n \times n$ 
3   para  $j$  de 1 à  $n$  faça
4     para  $i$  de  $j+1$  à  $m$  faça
5       se  $a_{ij} \neq 0$  então
6          $c_{ij} \leftarrow a_{ij} / \sqrt{a_{ij}^2 + a_{ij}^2}$  Supondo  $a_{ij}, a_{ij} \neq 0$ 
7          $s_{ij} \leftarrow a_{ij} / \sqrt{a_{ij}^2 + a_{ij}^2}$ 
8          $a_j, a_i \leftarrow a_j c_{ij} + a_i s_{ij}, a_j(-s_{ij}) + a_i c_{ij}$ 
9          $q_j, q_i \leftarrow q_j c_{ij} + q_i s_{ij}, q_j(-s_{ij}) + q_i c_{ij}$ 
10        fim
11      fim
12    fim
13     $Q \leftarrow Q^t$ 
14     $R \leftarrow A$ 
15    retorna Q,R
16 fim

```

3. Quadrados mínimos via decomposição QR

Como a decomposição QR ajuda no Problema de Quadrados Mínimos?

Se $A = QR$, pela Proposição 1, podemos resolver o Problema de Quadrados Mínimos de (A, b) como

$$\begin{aligned} \|Ax - b\|_2^2 &= \|QRx - b\|_2^2 \\ &= \|Q^t(QRx - b)\|_2^2 \\ &= \|Rx - Q^t b\|_2^2 \\ &= \|\hat{R}x - c\|_2^2 + \|d\|_2^2 \end{aligned}$$

Onde

$$R = \begin{pmatrix} \hat{R} & \\ & 0 \end{pmatrix} \quad Q^t b = \begin{pmatrix} c \\ d \end{pmatrix}$$

Assim, basta resolver o sistema triangular $\hat{R}x = c$. A resolução de quadrados mínimos por decomposição QR é dada pelo algoritmo abaixo.

Algoritmo 3: RESOLUÇÃO DE QUADRADOS MÍNIMOS

```

Entrada:  $A \in \mathbb{R}^{n \times m}$ ,  $b \in \mathbb{R}^{m \times 1}$ 
Saída:  $\hat{x} \in \mathbb{R}^{m \times 1}$  solução de  $\min_{x \in \mathbb{R}^m} \|Ax - b\|_2^2$ 
1 início
2   Q, R  $\leftarrow$  Decomposição QR de A
3    $R_1 \leftarrow R[1 : m, :]$ 
4    $b \leftarrow Q^t b$ 
5    $b_1 \leftarrow b[1 : m]$ 
6    $\hat{x} \leftarrow R_1^{-1} b_1$ 
7   retorna  $\hat{x}$ 
8 fim


```

4. Aplicação


Vejamos uma aplicação na indústria de molas. Para obter a constante da mola k proveniente da Lei de Hooke $F = -kx$ são utilizadas medições da força aplicada à mola F e o deslocamento x obtido. A partir das medições, obtemos as seguintes relações:

$$\begin{aligned} 4.0k + p &= 2.614 \\ 6.0k + p &= 5.7309 \\ 8.0k + p &= 7.2909 \\ 10.0k + p &= 6.4058 \\ 12.0k + p &= 9.6112 \\ 14.0k + p &= 12.9009 \end{aligned}$$

Representadas no gráfico:



Aplicando o algoritmo de decomposição QR por rotação em A , obtemos $k = 0.8884$ e $p = 0.5703$. Ou seja, a reta que melhor aproxima esses pontos é: $F = 0.0884x - 0.5703$. Graficamente:



5. Exemplos

Exemplo 1: (Matrizes esparsas) Utilizamos a biblioteca SparseArrays para criar uma matriz $A \in \mathbb{R}^{10 \times 10}$ esparsa arbitrária e um vetor $b \in \mathbb{R}^{10}$ também arbitrário, obtemos:

	Tempo (s)	Alocações	Memória
Gram-Schmidt	0.0000150070	351 allocations	57.81 KiB
Rotação	0.0000021864	30 allocations	8.02 KiB

Note que o método das rotações de Givens é mais eficiente.

Exemplo 2: (Matrizes densas) Criando uma matriz densa arbitrária $A \in \mathbb{R}^{10 \times 10}$ e $b \in \mathbb{R}^{10}$ um vetor arbitrário, obtemos:

	Tempo (s)	Alocações	Memória
Gram-Schmidt	0.0000152320	351 allocations	57.81 KiB
Rotação	0.0000409430	910 allocations	145.52 KiB

Já neste exemplo, o método mais vantajoso é o processo de Gram-Schmidt.

6. Comparação dos métodos

Nos exemplos acima podemos ver uma grande diferença entre os valores obtidos, principalmente se tratando de memória utilizada e alocações, sendo que no exemplo 1, a rotação é muito melhor que Gram-Schmidt e no exemplo 2 temos o contrário.

Isso acontece porque para matrizes esparsas o método da rotação é de fato muito mais eficiente, pois quando o aplicamos, procuramos zerar elementos da matriz para encontrar a matriz R no formato triangular superior. Se a matriz já tem vários zeros (esparsa), então não precisamos zerá-los, portanto, o algoritmo da rotação pulará diversos passos.

Já para matrizes densas, como no exemplo 2, não há zeros na matriz 10×10 , e portanto, para o método de rotação é necessário zerar diversas entradas, ao invés de "pular" algumas, como acontece com matrizes esparsas. Por conta disso, o método de Gram-Schmidt se torna mais vantajoso, já que utiliza menos memória e realiza menos alocações comparado ao método da rotação de Givens.

Concluímos que não podemos generalizar uma maneira mais eficiente de se calcular a fatoração QR, já que para o caso de matrizes esparsas, o preferível é utilizar as rotações de Givens e, para matrizes densas, o melhor é o processo de Gram-Schmidt.

Entretanto, é vantajoso usar métodos QR para resolver estes problemas, já que o custo computacional é bem menor do que ao utilizar o método tradicional (invertendo matrizes).

Referências

- [1] ARAUJO, T. P. *Álgebra Linear: Teoria e Aplicações*, SBM, 2014.
- [2] STRANGE, G. *Introduction to Linear Algebra* Wellesley, Cambridge Press, 2009.
- [3] WATKINS, D. S. *Fundamentals of Matrix Computations*, Wiley-Interscience, 2002.
- [4] STEWART, G. W. *Introduction to Matrix Computation*, Academic Press, 1973.
- [5] AXLER, S. *Linear Algebra Done Right*, Springer, 2004.