

## PageRank da Matriz *Google* Através do Método da Potência

Matheus M. Nery <sup>1</sup>

Bacharel em Matemática/UFF, Volta Redonda, RJ

Marina S. D. de Freitas<sup>2</sup>

VMA/UFF, Volta Redonda, RJ

O método da potência é um algoritmo iterativo utilizado para encontrar o autovalor de maior magnitude (em valor absoluto) e seu autovetor associado de uma matriz quadrada  $A$ . Ele funciona tomando algum vetor arbitrário de norma 1 e multiplicando esse vetor por uma matriz  $A$ , obtendo, assim, um novo vetor, o qual será normalizado. O processo é repetido até que essa sequência de vetores gerados convirja para um autovetor correspondente ao maior autovalor de  $A$  [3]. Na Figura 1, temos o algoritmo desse método.

**Método da potência**  
 $A$  uma matriz  $n \times n$   
 $v_0 =$  algum vetor com  $\|v_0\| = 1$   
 $k = 1$   
**repita**  
 $w_k = Av_{k-1}$   
 $v_k = \frac{w_k}{\|w_k\|}$  (autovetor aproximado)  
 $\lambda_k = (v_k)^T Av_k$  (autovalor aproximado)  
 $k = k + 1$   
**até a convergência.**

Figura 1: algoritmo da iteração de potência. Fonte: Adaptado de [1].

O método da potência é eficiente para matrizes grandes e esparsas, pois dispensa a fatoração completa da matriz. Uma das aplicações mais conhecidas é o cálculo do *PageRank*, uma métrica criada por Larry Page e Sergey Brin para avaliar a importância de páginas na *web*.

O *PageRank* é um autovetor da matriz do *Google*, que representa um grafo onde os vértices são páginas *web* e as arestas são os *links* entre elas. A relevância de cada página é determinada com base na quantidade e qualidade dos *links* que apontam para ela. Este conceito fundamenta-se na premissa de que a quantidade de *links* direcionados para uma página e oriundos dela fornece informações relevantes sobre a sua importância [2].

No cálculo do *PageRank*, as páginas da *web* são ordenadas de 1 a  $n$ , e a matriz  $Q$  é definida como:

$$Q_{ij} = \begin{cases} \frac{1}{N_j}, & \text{se há um link de } j \text{ para } i \\ 0, & \text{caso contrário,} \end{cases} \quad (1)$$

onde  $N_j$  é o número de *links* de saída da página  $j$ . O *rank* de  $i$ , denotado por  $r_i$ , é definido de tal forma que, se uma página  $j$ , altamente classificada, tiver um *link* de saída para  $i$ , isto aumenta a

<sup>1</sup>matheus.mneryy@gmail.com

<sup>2</sup>msdias@id.uff.br

importância de  $i$ . A definição preliminar do *PageRank* é:

$$r_i = \sum_{j \in I_i} \frac{r_j}{N_j}, \quad (2)$$

onde  $I_i$  é o conjunto de páginas que possuem um *link* para a página  $i$ . Esta definição é recursiva, portanto o *PageRank* não pode ser calculado diretamente. Assim, dado  $\mathbf{r}_0$  o vetor com o *rank* inicial de cada página, após  $k + 1$  iterações, temos:

$$r_i^{(k+1)} = \sum_{j \in I_i} \frac{r_j^{(k)}}{N_j}, \text{ para } k = 0, 1, \dots \quad (3)$$

Esse processo reflete a importância relativa de cada página, com base nos *links* recebidos.

O *PageRank* permite filtrar páginas irrelevantes em pesquisas, priorizando aquelas com maior relevância. O cálculo iterativo, iniciado com um vetor  $\mathbf{r}_0$ , converge para o autovetor que representa a importância de cada página, demonstrando a eficácia do método da potência em problemas de grande escala. Pode-se observar que a definição (2) é equivalente a multiplicar a linha  $i$  da matriz  $Q$  pelo vetor  $\mathbf{r}$ , que contém o *rank* de todas as páginas. Assim, pode-se escrever a equação na forma matricial  $\lambda \mathbf{r} = Q\mathbf{r}$ ,  $\lambda = 1$ . Portanto, a iteração (3) é equivalente a  $\mathbf{r}^{k+1} = Q\mathbf{r}^k$ ,  $k = 0, 1, \dots$ , que corresponde ao método da potência para calcular o autovetor. Assim, queremos resolver o problema de autovalores  $A\mathbf{r} = \mathbf{r}$ , onde  $\|\mathbf{r}\| = 1$ . Note que a matriz  $A$  é esparsa e sua dimensão é da ordem de bilhões. Para realizar este cálculo, propomos o método da potência.

Para garantir que o *PageRank* esteja bem definido e que existe um autovalor igual a 1, precisamos fazer algumas modificações. A matriz  $Q$  é modificada de modo que, se uma página não possui *link* para nenhuma outra, então a coluna de  $Q$  composta de zeros é modificada por um valor constante em cada posição. Isto significa que existe igual probabilidade de ir para qualquer página na rede. Assim,  $Q$  passa a ter a forma:  $P = Q + \frac{1}{n}\mathbf{e}\mathbf{d}^T$ , onde  $\mathbf{e}, \mathbf{d} \in \mathbb{R}^n$ ,  $\mathbf{e}^T = (1, 1, \dots, 1)$  e  $d_j = 1$ , se  $N_j = 0$  e 0 caso contrário. A matriz  $P$  obtida é uma matriz coluna-estocástica, isto é, ela possui apenas elementos não negativos e os elementos de cada coluna somam 1. Reescrevendo  $\lambda \mathbf{r} = Q\mathbf{r}$ , obtemos  $P\mathbf{r} = \mathbf{r}$ . Além disso, para garantir que exista um *link* de toda página da *web* para outra, é feita uma combinação convexa de  $P$  e uma matriz de posto 1:  $A = \alpha P + (1 - \alpha)\frac{1}{n}\mathbf{e}\mathbf{e}^T$ , para algum  $\alpha$  satisfazendo  $0 \leq \alpha \leq 1$ . Para a convergência do algoritmo, devemos conhecer como os autovalores de  $P$  se alteram após sua modificação, o que é mostrado no Teorema 1.

**Teorema 1.** *Suponha que os autovalores da matriz coluna-estocástica  $P$  sejam  $\{1, \lambda_2, \lambda_3, \dots, \lambda_n\}$ . Então os autovalores de  $A = \alpha P + (1 - \alpha)\frac{1}{n}\mathbf{e}\mathbf{e}^T$  são  $\{1, \alpha\lambda_2, \alpha\lambda_3, \dots, \alpha\lambda_n\}$ .*

O Teorema 1 implica que mesmo que  $P$  tenha múltiplos autovalores iguais a 1, o que é verdadeiro para a matriz *Google*, o segundo maior autovalor em magnitude de  $A$  é sempre igual a  $\alpha$ . Uma vantagem adicional é que não precisamos utilizar o vetor  $\mathbf{d}$  em nenhum momento, o que significa que não é necessário saber quais páginas não possuem *links* de saída.

## Referências

- [1] J. W. Demmel. **Applied Numerical Linear Algebra**. 1a. ed. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 1997. ISBN: 9780898713893.
- [2] L. Eldén. “Numerical Linear Algebra in Data Mining”. Em: **Acta Numerica** 15 (2006), pp. 327–384. DOI: 10.1017/S0962492906240017.
- [3] L. N. Trefethen e D. Bau. **Numerical Linear Algebra**. 1a. ed. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 1997. ISBN: 9780898713619.