

Introdução às Redes de Interação – MO804 (MC908)

Redes dinâmicas: principais modelos

Prof. Dr. Ruben Interian

Instituto de Computação, UNICAMP

Resumo

- 1 Objetivo
- 2 Lei de potência
- 3 Modelo BA

Resumo

- 1 Objetivo
- 2 Lei de potência
- 3 Modelo BA

Objetivo

- **Lei de potência**: origem, propriedades e importância.
- **Modelo BA**, ou de conexão preferencial: algoritmo e características.

Lei de potência

- Consideremos alguma **rede real**, por exemplo, a rede de hiperlinks na **Web**, ou a rede usuários e seguidores de uma **rede social**.

Lei de potência

- Consideremos alguma **rede real**, por exemplo, a rede de hiperlinks na **Web**, ou a rede usuários e seguidores de uma **rede social**.
- O **grau** (neste caso, de entrada) de um vértice v_i é a **popularidade** de v_i .

Lei de potência

- Consideremos alguma **rede real**, por exemplo, a rede de hiperlinks na **Web**, ou a rede usuários e seguidores de uma **rede social**.
- O **grau** (neste caso, de entrada) de um vértice v_i é a **popularidade** de v_i .
- Suponha que temos uma **foto** (*snapshot*) da rede em um determinado instante.

Lei de potência

- Consideremos alguma **rede real**, por exemplo, a rede de hiperlinks na **Web**, ou a rede usuários e seguidores de uma **rede social**.
- O **grau** (neste caso, de entrada) de um vértice v_i é a **popularidade** de v_i .
- Suponha que temos uma **foto** (*snapshot*) da rede em um determinado instante.
- O que podemos esperar da quantidade de vértices (usuários, ou páginas) que possuem grau k , para cada k ? Ou seja queremos saber como a **popularidade é distribuída** entre os vértices.

Lei de potência

Primeira ideia: supor que a distribuição dos graus é aproximadamente **normal**.

- **Lembrando:** A distribuição normal **ocorre naturalmente** em diversas áreas de ciências naturais e ciências exatas.

Lei de potência

Primeira ideia: supor que a distribuição dos graus é aproximadamente **normal**.

- **Lembrando:** A distribuição normal **ocorre naturalmente** em diversas áreas de ciências naturais e ciências exatas.
- Uma quantidade que é resultado da **soma de muitas variáveis independentes menores**, é **aproximadamente normal** (\Rightarrow Teorema Central do Limite).

Lei de potência

Primeira ideia: supor que a distribuição dos graus é aproximadamente **normal**.

- **Lembrando:** A distribuição normal **ocorre naturalmente** em diversas áreas de ciências naturais e ciências exatas.
- Uma quantidade que é resultado da **soma de muitas variáveis independentes menores**, é **aproximadamente normal** (\Rightarrow Teorema Central do Limite).
- **Consequência:** se diferentes usuários/páginas decidem com quem ter vínculos de forma independente e aleatória, então o grau/popularidade de cada página é a soma de variáveis aleatórias independentes, e **deveria ter** distribuição normal.

Lei de potência

- Fato sobre distribuições normais: a probabilidade de observar um valor que fica a x **desvios padrões** da média **decrece exponencialmente** quando x aumenta.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Ou, no caso normal padrão:

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

Lei de potência

- Fato sobre distribuições normais: a probabilidade de observar um valor que fica a x **desvios padrões** da média **decrece exponencialmente** quando x aumenta.


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Ou, no caso normal padrão:

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

- Se acreditamos neste modelo, então o número de usuários/páginas com grau k deveria **decrecer exponencialmente** a medida de k aumenta.

Lei de potência



Lei de potência

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

Distribuição das observações no caso normal:

- 68.2% estão no intervalo \pm um desvio padrão da média;
- 95.4% estão no intervalo \pm dois desvios padrões da média; e
- 99.7% estão no intervalo \pm três desvios padrões da média.

Lei de potência

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

Distribuição das observações no caso normal:

- 68.2% estão no intervalo \pm um desvio padrão da média;
- 95.4% estão no intervalo \pm dois desvios padrões da média; e
- 99.7% estão no intervalo \pm três desvios padrões da média.

A expressão e^{-x} para $x = 100$ já é $4 \cdot 10^{-44}$. E dentro da fórmula da PDF da distribuição normal temos $e^{-x^2/2}$, muito menor.

Lei de potência

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

Distribuição das observações no caso normal:

- 68.2% estão no intervalo \pm um desvio padrão da média;
- 95.4% estão no intervalo \pm dois desvios padrões da média; e
- 99.7% estão no intervalo \pm três desvios padrões da média.

A expressão e^{-x} para $x = 100$ já é $4 \cdot 10^{-44}$. E dentro da fórmula da PDF da distribuição normal temos $e^{-x^2/2}$, muito menor.

Não devemos ter observações distando muitos desvios padrões da média, ou para isso precisaríamos de um dataset gigante!

Lei de potência

Mas, o que observamos **empiricamente, na realidade?**

Lei de potência

Mas, o que observamos **empiricamente, na realidade?** – **Exatamente o inverso!**
Há observações a dezenas e centenas de desvios padrões da média!

- A fração de **páginas na WEB** com grau de entrada k é proporcional, aproximadamente, a $\frac{1}{k^2}$. Se $k = 100$, este valor é $0.0001 = \frac{1}{10000}$.

Lei de potência

Mas, o que observamos **empiricamente, na realidade?** – **Exatamente o inverso!**
Há observações a dezenas e centenas de desvios padrões da média!

- A fração de **páginas na WEB** com grau de entrada k é proporcional, aproximadamente, a $\frac{1}{k^2}$. Se $k = 100$, este valor é $0.0001 = \frac{1}{10000}$.
- A parcela de **celulares** que recebem k chamadas por dia é proporcional, aproximadamente, a $\frac{1}{k^2}$.

Lei de potência

Mas, o que observamos **empiricamente, na realidade?** – **Exatamente o inverso!**
Há observações a dezenas e centenas de desvios padrões da média!

- A fração de **páginas na WEB** com grau de entrada k é proporcional, aproximadamente, a $\frac{1}{k^2}$. Se $k = 100$, este valor é $0.0001 = \frac{1}{10000}$.
- A parcela de **celulares** que recebem k chamadas por dia é proporcional, aproximadamente, a $\frac{1}{k^2}$.
- A parcela de **livros comprados** por k pessoas é proporcional, aproximadamente, a $\frac{1}{k^3}$.

Lei de potência

Mas, o que observamos **empiricamente, na realidade?** – **Exatamente o inverso!**
Há observações a dezenas e centenas de desvios padrões da média!

- A fração de **páginas na WEB** com grau de entrada k é proporcional, aproximadamente, a $\frac{1}{k^2}$. Se $k = 100$, este valor é $0.0001 = \frac{1}{10000}$.
- A parcela de **celulares** que recebem k chamadas por dia é proporcional, aproximadamente, a $\frac{1}{k^2}$.
- A parcela de **livros comprados** por k pessoas é proporcional, aproximadamente, a $\frac{1}{k^3}$.
- A parcela de **artigos científicos** que recebem k citações é proporcional, aproximadamente, a $\frac{1}{k^3}$.

Lei de potência

Mas, o que observamos **empiricamente, na realidade?** – **Exatamente o inverso!**
Há observações a dezenas e centenas de desvios padrões da média!

- A fração de **páginas na WEB** com grau de entrada k é proporcional, aproximadamente, a $\frac{1}{k^2}$. Se $k = 100$, este valor é $0.0001 = \frac{1}{10000}$.
- A parcela de **celulares** que recebem k chamadas por dia é proporcional, aproximadamente, a $\frac{1}{k^2}$.
- A parcela de **livros comprados** por k pessoas é proporcional, aproximadamente, a $\frac{1}{k^3}$.
- A parcela de **artigos científicos** que recebem k citações é proporcional, aproximadamente, a $\frac{1}{k^3}$.

Parece que a distribuição tem uma característica conhecida como **cauda longa**: há muito mais dados ao longo da cauda, quando comparamos a uma Gaussiana.

Lei de potência

Resumo: **redes reais** não parecem ter distribuições dos graus dos vértices parecidas à normal. A normal funciona apenas em redes aleatórias!

As **distribuições dos graus em redes reais** são **mais parecidas a** $\frac{1}{k^\alpha}$.

Lei de potência

Resumo: **redes reais** não parecem ter distribuições dos graus dos vértices parecidas à normal. A normal funciona apenas em redes aleatórias!

As **distribuições dos graus em redes reais** são **mais parecidas a $\frac{1}{k^\alpha}$** .

Uma relação funcional do tipo $y = b \frac{1}{x^\alpha} = bx^{-\alpha}$ é chamada **lei de potência**, onde:

- x é a variável independente,
- y é a variável dependente (a frequência),
- b é a constante de proporcionalidade, e
- α é outra constante (o expoente).

Lei de potência

$$y = b \frac{1}{x^\alpha} = bx^{-\alpha}$$

Primeira propriedade importante da lei de potência:

$$\log y = \log(bx^{-\alpha}) = \log b + \log x^{-\alpha} = -\alpha \log x + \log b.$$

Lei de potência


$$y = b \frac{1}{x^\alpha} = bx^{-\alpha}$$

Primeira propriedade importante da lei de potência:

$$\log y = \log(bx^{-\alpha}) = \log b + \log x^{-\alpha} = -\alpha \log x + \log b.$$

Essa propriedade fornece um teste relativamente simples (mas não muito rigoroso), sobre se os seus dados seguem uma **lei de potência**: se o gráfico dos valores de $\log x$ e $\log y$ é, aproximadamente, uma **reta**, temos um indicador de que a distribuição é uma **lei de potência**.

Lei de potência



Lei de potência

$$y = b \frac{1}{x^\alpha} = bx^{-\alpha}$$

Segunda propriedade importante da lei de potência:

$$y(cx) = b(cx)^{-\alpha} = c^{-\alpha} \cdot bx^{-\alpha} = c^{-\alpha}y(x) \propto y(x)$$

Lei de potência

$$y = b \frac{1}{x^\alpha} = bx^{-\alpha}$$

Segunda propriedade importante da lei de potência:

$$y(cx) = b(cx)^{-\alpha} = c^{-\alpha} \cdot bx^{-\alpha} = c^{-\alpha}y(x) \propto y(x)$$

Esta propriedade é chamada de **invariância de escala**, e significa que ao multiplicar o argumento x por um fator constante c , obtemos apenas a própria função em um outro nível de escala (**autossimilaridade**).

Lei de potência

A **lei de potência** é observada em diversos domínios, e pode ser considerada uma **lei geral da natureza**. Em particular, se uma quantidade x reflete algum tipo de **popularidade** (mas não apenas nesses casos!), geralmente surge a **lei de potência**.

- Pessoas “famosas” e influenciadores – número de seguidores;
- Livros – quantidade de vendas;
- Sites na Internet – links para o site;
- Artigos científicos – número de citações;
- Cidades – número de habitantes;
- Músicas em um serviço de *streaming* – número de downloads;
- Palavras em textos – frequências de uso;
- Rendimentos dos contribuintes – valor de ingressos anuais;
- Tamanho das erupções solares, força dos terremotos ...

Lei de potência

Curiosidades: Suponha que temos a lei de potência $x^{-\alpha}$.

- O valor da **média** está bem definido (é finito) somente se $\alpha > 2$.
Existe **variância** finita somente se $\alpha > 3$.

Lei de potência

Curiosidades: Suponha que temos a lei de potência $x^{-\alpha}$.

- O valor da **média** está bem definido (é finito) somente se $\alpha > 2$.
Existe **variância** finita somente se $\alpha > 3$.
- **Interpretação:** se $\alpha \leq 3$, então ao pegar amostras finitas (por exemplo, graus de vértices em redes cada vez maiores), teremos nós com **graus cada vez maiores**, e a variância irá aumentar.

Lei de potência

Curiosidades: Suponha que temos a lei de potência $x^{-\alpha}$.

- O valor da **média** está bem definido (é finito) somente se $\alpha > 2$.
Existe **variância** finita somente se $\alpha > 3$.
- **Interpretação:** se $\alpha \leq 3$, então ao pegar amostras finitas (por exemplo, graus de vértices em redes cada vez maiores), teremos nós com **graus cada vez maiores**, e a variância irá aumentar.
- Na maioria dos **casos reais**, o expoente fica exatamente no intervalo $(2, 3)$, o que significa que a média é bem definida, mas a variância não.

Lei de potência

Curiosidades: Suponha que temos a lei de potência $x^{-\alpha}$.

- O valor da **média** está bem definido (é finito) somente se $\alpha > 2$.
Existe **variância** finita somente se $\alpha > 3$.
- **Interpretação:** se $\alpha \leq 3$, então ao pegar amostras finitas (por exemplo, graus de vértices em redes cada vez maiores), teremos nós com **graus cada vez maiores**, e a variância irá aumentar.
- Na maioria dos **casos reais**, o expoente fica exatamente no intervalo $(2, 3)$, o que significa que a média é bem definida, mas a variância não.
- Este fato implica na ocorrência de observações raras e difíceis de prever (chamadas “cisnes negros”) que estão além do escopo das nossas expectativas “normais”.
Exemplos: **popularidade inesperada** de um usuário, uma notícia ou um vídeo.

Lei de potência

Um caso específico da lei de potência leva ao famoso **Princípio de Pareto**, ou **regra 80/20**:

Lei de potência

Um caso específico da lei de potência leva ao famoso **Princípio de Pareto**, ou **regra 80/20**:

- “80% dos efeitos vêm de 20% das causas”: ao corrigir 20% dos bugs (mais relatados), eliminamos 80% dos erros presentes no sistema [Microsoft].



Lei de potência

Um caso específico da lei de potência leva ao famoso **Princípio de Pareto**, ou **regra 80/20**:

- “80% dos efeitos vêm de 20% das causas”: ao corrigir 20% dos bugs (mais relatados), eliminamos 80% dos erros presentes no sistema [Microsoft].
- O 20% das pessoas mais ricas recebem 80% da renda.

Lei de potência: Exemplos


Distribuições reais que seguem a Lei de Potencia: **População das cidades**



population of city


Lei de potência: Exemplos

Distribuições reais que seguem a Lei de Potencia: **Palavras no texto, frequências**




Lei de potência: Exemplos

Distribuições reais que seguem a Lei de Potencia: **Sobrenomes, frequências**



Lei de potência: Exemplos

Distribuições reais que seguem a Lei de Potencia: **Diâmetros das crateras lunares**



Redes dinâmicas: modelo BA

Lembrando: O modelo de **conexão preferencial**, ou Barabási-Albert (BA), é um modelo **estocástico e populacional**.

Redes dinâmicas: modelo BA

Lembrando: O modelo de **conexão preferencial**, ou Barabási-Albert (BA), é um modelo **estocástico e populacional**.

- As **distribuições dos graus** dos vértices em muitas redes reais obedecem a **Lei de Potencia**.

Redes dinâmicas: modelo BA

Lembrando: O modelo de **conexão preferencial**, ou Barabási-Albert (BA), é um modelo **estocástico e populacional**.

- As **distribuições dos graus** dos vértices em muitas redes reais obedecem a **Lei de Potencia**.
- **Ideia da conexão preferencial:** quanto **maior** o grau (“popularidade”) do nó, **maior** é a chance de ele receber novas arestas (mais rápido o grau aumentará).

Redes dinâmicas: modelo BA

Lembrando: O modelo de **conexão preferencial**, ou Barabási-Albert (BA), é um modelo **estocástico e populacional**.

- As **distribuições dos graus** dos vértices em muitas redes reais obedecem a **Lei de Potencia**.
- **Ideia da conexão preferencial:** quanto **maior** o grau (“popularidade”) do nó, **maior** é a chance de ele receber novas arestas (mais rápido o grau aumentará).
- **Na prática**, isso significa que um vértice **novo** w na rede cria uma aresta com um vértice existente v_i com probabilidade proporcional ao grau $d(v_i) = k_i$.

Redes dinâmicas: modelo BA

- Se P_i é a probabilidade do evento “o vértice novo w escolheu v_i ”, então:

$$P_i = \frac{k_i}{\sum_j k_j}.$$

Redes dinâmicas: modelo BA

- Se P_i é a probabilidade do evento “o vértice novo w escolheu v_i ”, então:

$$P_i = \frac{k_i}{\sum_j k_j}.$$

- A expressão $\sum_j k_j$ é igual a $2|E|$ em grafos não direcionados (ou $|E|$ em grafos direcionados, onde consideramos os graus de entrada).

Redes dinâmicas: modelo BA

- Se P_i é a probabilidade do evento “o vértice novo w escolheu v_i ”, então:

$$P_i = \frac{k_i}{\sum_j k_j}.$$

- A expressão $\sum_j k_j$ é igual a $2|E|$ em grafos não direcionados (ou $|E|$ em grafos direcionados, onde consideramos os graus de entrada).
- Cada vértice adiciona uma aresta a algum vértice existente com probabilidade P_i .

Redes dinâmicas: modelo BA

- Se P_i é a probabilidade do evento “o vértice novo w escolheu v_i ”, então:

$$P_i = \frac{k_i}{\sum_j k_j}.$$

- A expressão $\sum_j k_j$ é igual a $2|E|$ em grafos não direcionados (ou $|E|$ em grafos direcionados, onde consideramos os graus de entrada).
- Cada vértice adiciona uma aresta a algum vértice existente com probabilidade P_i .
- Podemos adicionar não um, mas m vínculos para cada vértice. A essência do modelo e dos resultados **não muda** neste caso.

Redes dinâmicas: modelo BA

- Se P_i é a probabilidade do evento “o vértice novo w escolheu v_i ”, então:

$$P_i = \frac{k_i}{\sum_j k_j}.$$

- A expressão $\sum_j k_j$ é igual a $2|E|$ em grafos não direcionados (ou $|E|$ em grafos direcionados, onde consideramos os graus de entrada).
- Cada vértice adiciona uma aresta a algum vértice existente com probabilidade P_i .
- Podemos adicionar não um, mas m vínculos para cada vértice. A essência do modelo e dos resultados **não muda** neste caso.
- Existem variantes do modelo BA para grafos **direcionados e não direcionados**. Inicialmente veremos o modelo mais simples para o caso **não direcionado**.

Redes dinâmicas: modelo BA (simplificado)

BA (N)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 4: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

Redes dinâmicas: modelo BA (simplificado)

BA (N)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 4: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

- **Sutileza:** Iniciamos no vértice 3. Motivo: o 1^{ro} vértice não recebe arestas. Mas ao colocar o 2^{do} vértice, precisamos colocar a aresta para o primeiro!

Redes dinâmicas: modelo BA (simplificado)

BA (N)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 4: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

- **Sutileza:** Iniciamos no vértice 3. Motivo: o 1^{ro} vértice não recebe arestas. Mas ao colocar o 2^{do} vértice, precisamos colocar a aresta para o primeiro!
- Este modelo é **equivalente** a sempre começar com um caminho de tamanho 3!

Redes dinâmicas: modelo BA (simplificado)

BA (N)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 4: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

- **Sutileza:** Iniciamos no vértice 3. Motivo: o 1^{ro} vértice não recebe arestas. Mas ao colocar o 2^{do} vértice, precisamos colocar a aresta para o primeiro!
- Este modelo é **equivalente** a sempre começar com um caminho de tamanho 3!
- **Alternativa:** começar com outro grafo, e ir adicionando vértices e arestas.

Redes dinâmicas: modelo BA

Características: o modelo gera uma rede **livre de escala** cuja distribuição de graus segue uma lei de potência $bx^{-\alpha}$. Vamos **provar** este fato.

Redes dinâmicas: modelo BA

Características: o modelo gera uma rede **livre de escala** cuja distribuição de graus segue uma lei de potência $bx^{-\alpha}$. Vamos **provar** este fato.

- O comportamento dos graus dos vértices vai ser definido pela função real $k_i(t)$ que indica o valor esperado do grau no momento de tempo t (iteração i , quando temos $N(t)$ vértices).

Redes dinâmicas: modelo BA

Características: o modelo gera uma rede **livre de escala** cuja distribuição de graus segue uma lei de potência $bx^{-\alpha}$. Vamos **provar** este fato.

- O comportamento dos graus dos vértices vai ser definido pela função real $k_i(t)$ que indica o valor esperado do grau no momento de tempo t (iteração i , quando temos $N(t)$ vértices). A velocidade de crescimento (a derivada) dessa função é:

$$\frac{dk_i}{dt} = mP_i = m \frac{k_i}{\sum_{j=1}^{N-1} k_j}$$

- No nosso caso, $m = 1$, mas podemos estudar o modelo com qualquer número de vínculos adicionados por cada vértice.

Redes dinâmicas: modelo BA

- O número de arestas após t iterações é mt , e a soma de graus é $2mt$:

$$\frac{dk_i}{dt} = m \frac{k_i}{2mt} = \frac{k_i}{2t}.$$

Redes dinâmicas: modelo BA

- O número de arestas após t iterações é mt , e a soma de graus é $2mt$:

$$\frac{dk_i}{dt} = m \frac{k_i}{2mt} = \frac{k_i}{2t}.$$

- Reescrevemos a equação e integramos:

$$\frac{dk_i}{k_i} = \frac{dt}{2t}$$

$$\ln k_i = \frac{\ln t}{2} + C$$

Redes dinâmicas: modelo BA

$$k_i = e^{\frac{1}{2} \ln t + C} = C' t^{\frac{1}{2}}$$

Redes dinâmicas: modelo BA

$$k_i = e^{\frac{1}{2} \ln t + C} = C' t^{\frac{1}{2}}$$

- Para calcular o valor de C' , usamos o fato que no momento ou iteração t_i , quando o i -ésimo vértice aparece, $k_i(t_i) = C' t_i^{\frac{1}{2}} = m$:

Redes dinâmicas: modelo BA

$$k_i = e^{\frac{1}{2} \ln t + C} = C' t^{\frac{1}{2}}$$

- Para calcular o valor de C' , usamos o fato que no momento ou iteração t_i , quando o i -ésimo vértice aparece, $k_i(t_i) = C' t_i^{\frac{1}{2}} = m$:

$$C' = m / t_i^{\frac{1}{2}}$$

$$k_i = \left(\frac{t}{t_i} \right)^{\frac{1}{2}} m.$$

- Essa fórmula mostra como evolui o grau do vértice no tempo.

Redes dinâmicas: modelo BA

- Agora, precisamos analisar a **distribuição** dos valores de k_i . Primeiramente, vamos calcular a função de distribuição acumulada $F(k_i)$:

$$F(k_i) = P(k_i(t) \leq k)$$

Redes dinâmicas: modelo BA

- Agora, precisamos analisar a **distribuição** dos valores de k_i . Primeiramente, vamos calcular a função de distribuição acumulada $F(k_i)$:

$$F(k_i) = P(k_i(t) \leq k)$$

$$\left(\frac{t}{t_i}\right)^{\frac{1}{2}} m \leq k$$

$$\frac{t}{t_i} \leq \left(\frac{k}{m}\right)^2$$

$$t_i \geq t \left(\frac{m}{k}\right)^2$$

Redes dinâmicas: modelo BA

$$P\left(t_i \geq t \left(\frac{m}{k}\right)^2\right) = 1 - P\left(t_i < t \left(\frac{m}{k}\right)^2\right)$$

Redes dinâmicas: modelo BA

$$P\left(t_i \geq t \left(\frac{m}{k}\right)^2\right) = 1 - P\left(t_i < t \left(\frac{m}{k}\right)^2\right)$$

- Todos os nós são adicionados em intervalos de tempo iguais: $P(t_i) = \frac{1}{t}$.

$$1 - \frac{1}{t} t \left(\frac{m}{k}\right)^2 = 1 - \left(\frac{m}{k}\right)^2 = F(k_i)$$

Redes dinâmicas: modelo BA

$$P\left(t_i \geq t \left(\frac{m}{k}\right)^2\right) = 1 - P\left(t_i < t \left(\frac{m}{k}\right)^2\right)$$

- Todos os nós são adicionados em intervalos de tempo iguais: $P(t_i) = \frac{1}{t}$.

$$1 - \frac{1}{t} t \left(\frac{m}{k}\right)^2 = 1 - \left(\frac{m}{k}\right)^2 = F(k_i)$$

- Falta apenas encontrar a derivada da distribuição acumulada para calcular a PDF:

$$F'(k_i) = -m^2(k^{-2})' = 2m^2k^{-3} = \frac{2m^2}{k^3}.$$

Redes dinâmicas: modelo BA

Resumo:

- O expoente α da lei de potência desta variante do modelo é igual a 3 – temos lei de potência.

Redes dinâmicas: modelo BA

Resumo:

- O expoente α da lei de potência desta variante do modelo é igual a 3 – temos lei de potência.
- Porém, é um modelo limitado, pois gera redes com apenas um valor em específico de α .

Redes dinâmicas: modelo BA

Resumo:

- O expoente α da lei de potência desta variante do modelo é igual a 3 – temos lei de potência.
- Porém, é um modelo limitado, pois gera redes com apenas um valor em específico de α .

Como **generalizar** o modelo para que gere distribuições de graus com valores de α diferentes?

Redes dinâmicas: modelo BA (generalizado)

Generalização do modelo Barabási-Albert:

BA (N, p)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: **se** $\text{Random}(0, 1) \leq p$ **então**
 - 4: Escolher um vértice aleatório j , onde $1 \leq j \leq i - 1$.
 - 5: **senão**
 - 6: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 7: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

Redes dinâmicas: modelo BA (generalizado)

Generalização do modelo Barabási-Albert:

BA (N, p)

- 1: $E \leftarrow \{(1, 2)\}$
 - 2: **para cada** $i = 3, \dots, N$ **faça**
 - 3: **se** $\text{Random}(0, 1) \leq p$ **então**
 - 4: Escolher um vértice aleatório j , onde $1 \leq j \leq i - 1$.
 - 5: **senão**
 - 6: Escolher um vértice j , onde $1 \leq j \leq i - 1$, com probabilidade P_j .
 - 7: $E \leftarrow E \cup \{(i, j)\}$
- devolva** E
-

Este modelo foi originalmente definido e estudado para **grafos direcionados!**

Redes dinâmicas: modelo BA

Características: o modelo **generalizado** gera distribuições de graus que, *com alta probabilidade*, seguem a lei de potência com valores de α de aproximadamente $1 + \frac{1}{1-p}$.

Redes dinâmicas: modelo BA

Características: o modelo **generalizado** gera distribuições de graus que, *com alta probabilidade*, seguem a lei de potência com valores de α de aproximadamente $1 + \frac{1}{1-p}$.

Consequências:

- Se $p \approx 0$ (quase não há vínculos aleatórios), então $\alpha \approx 2$ para grafos **direcionados**. Para os não direcionados, já vimos que $\alpha = 3$ se $p = 0$.

Redes dinâmicas: modelo BA

Características: o modelo **generalizado** gera distribuições de graus que, *com alta probabilidade*, seguem a lei de potência com valores de α de aproximadamente $1 + \frac{1}{1-p}$.

Consequências:

- Se $p \approx 0$ (quase não há vínculos aleatórios), então $\alpha \approx 2$ para grafos **direcionados**. Para os não direcionados, já vimos que $\alpha = 3$ se $p = 0$.
- Se $p \approx 1$ (quase todos os vínculos são aleatórios), então α é grande (tende a ∞ quando $p \rightarrow 1$), e não há conexão preferencial. Este é o caso das redes aleatórias que já estudamos.

Redes dinâmicas: modelo BA

Características: o modelo **generalizado** gera distribuições de graus que, *com alta probabilidade*, seguem a lei de potência com valores de α de aproximadamente $1 + \frac{1}{1-p}$.

Consequências:

- Se $p \approx 0$ (quase não há vínculos aleatórios), então $\alpha \approx 2$ para grafos **direcionados**. Para os não direcionados, já vimos que $\alpha = 3$ se $p = 0$.
- Se $p \approx 1$ (quase todos os vínculos são aleatórios), então α é grande (tende a ∞ quando $p \rightarrow 1$), e não há conexão preferencial. Este é o caso das redes aleatórias que já estudamos.

De novo, podemos adicionar uma quantidade diferente de vínculos ($\neq 1$) em cada iteração. A essência do modelo e dos resultados **não muda** neste caso.

Redes dinâmicas: modelo BA

Exemplos de situações nas quais **surge a conexão preferencial** em redes:

- Pesquisadores, artigos **mais conhecidos**, recebem mais crédito (citações) do que um pesquisador/artigo comparativamente desconhecido, mesmo se o seu trabalho for similar. O crédito irá usualmente para pesquisadores que já são famosos.

Redes dinâmicas: modelo BA

Exemplos de situações nas quais **surge a conexão preferencial** em redes:

- Pesquisadores, artigos **mais conhecidos**, recebem mais crédito (citações) do que um pesquisador/artigo comparativamente desconhecido, mesmo se o seu trabalho for similar. O crédito irá usualmente para pesquisadores que já são famosos.

Caso do César Lattes: Embora Lattes tenha sido o principal pesquisador e primeiro autor do histórico artigo da Nature descrevendo o *meson pi*, Cecil Powell foi o único agraciado com o Prêmio Nobel de Física em 1950.

Redes dinâmicas: modelo BA

Exemplos de situações nas quais **surge a conexão preferencial** em redes:

- Rede de **interação de proteínas**: os mecanismos evolutivos, como a duplicação genética e o surgimento de novas funções genéticas, levam a redes de interação de proteínas de cauda longa, embora a distribuição específica hoje seja contestada.

Redes dinâmicas: modelo BA

Exemplos de situações nas quais **surge a conexão preferencial** em redes:

- Rede de **interação de proteínas**: os mecanismos evolutivos, como a duplicação genética e o surgimento de novas funções genéticas, levam a redes de interação de proteínas de cauda longa, embora a distribuição específica hoje seja contestada.

Essas redes podem parecer estáticas (herdamos genes e proteínas dos nossos pais), mas elas **não são**: durante milhões de anos, o número de genes cresceu de uns poucos para mais de 20.000 genes presentes em uma célula humana hoje.

Redes dinâmicas: modelo BA

Exemplos de situações nas quais **surge a conexão preferencial** em redes:

- Rede de **interação de proteínas**: os mecanismos evolutivos, como a duplicação genética e o surgimento de novas funções genéticas, levam a redes de interação de proteínas de cauda longa, embora a distribuição específica hoje seja contestada.


Essas redes podem parecer estáticas (herdamos genes e proteínas dos nossos pais), mas elas **não são**: durante milhões de anos, o número de genes cresceu de uns poucos para mais de 20.000 genes presentes em uma célula humana hoje.

- **Redes sociais**: usuários escolhem de quem serão seguidores.

Redes dinâmicas: modelo BA

Limitações do modelo BA:

nem todas as redes são livres de escala.



Redes dinâmicas: modelo BA

Limitações do modelo BA:
coeficientes de clusterização.

$$C_i \xrightarrow{n \rightarrow \infty} 0$$

Redes dinâmicas: modelo BA

Em resumo: O modelo Barabási-Albert gera redes **livres de escala** (*scale-free*), nas quais nós cujo grau é **várias vezes maior** do que a média (**hubs**) são muito mais frequentes.

Redes dinâmicas: modelo BA

Em resumo: O modelo Barabási-Albert gera redes **livres de escala** (*scale-free*), nas quais nós cujo grau é **várias vezes maior** do que a média (**hubs**) são muito mais frequentes.

- 1 Os **graus** dos vértices são **dissimilares** – a sua distribuição segue a lei de potência.

Redes dinâmicas: modelo BA

Em resumo: O modelo Barabási-Albert gera redes **livres de escala** (*scale-free*), nas quais nós cujo grau é **várias vezes maior** do que a média (**hubs**) são muito mais frequentes.

- 1 Os **graus** dos vértices são **dissimilares** – a sua distribuição segue a lei de potência.
- 2 Os **coeficientes de clusterização** são **baixos** (a medida que n cresce, $C_i \rightarrow 0$).

Redes dinâmicas: modelo BA

Em resumo: O modelo Barabási-Albert gera redes **livres de escala** (*scale-free*), nas quais nós cujo grau é **várias vezes maior** do que a média (**hubs**) são muito mais frequentes.

- 1 Os **graus** dos vértices são **dissimilares** – a sua distribuição segue a lei de potência.
- 2 Os **coeficientes de clusterização** são **baixos** (a medida que n cresce, $C_i \rightarrow 0$).
- 3 Os **caminhos mais curtos** são **pequenos** (na média crescem como $\log n$).

Redes dinâmicas: modelo BA

Valores das **principais métricas** em redes reais (dados de **diferentes fontes**).

Dataset	<i>diam</i>	$\overline{dist(v, w)}$	α	$C = \overline{C_i}$
Facebook	15	4.27	2.4	0.221
YouTube	21	5.10	2.0	0.136
Emails	13	3.39	2.1	0.497

Redes dinâmicas: modelo BA

Barabási e Albert fizeram a diferença com os seus trabalhos: eles explicaram um **grande conjunto de fenômenos reais**, tanto naturais como comportamentais, e revelaram o **mecanismo** de conexão preferencial por trás deste comportamento.

Dúvidas?