

# Introdução a Redes Complexas

Jornadas de Atualização em Informática (JAI)  
CSBC 2011

Encontro 2/3

Daniel R. Figueiredo  
LAND – PESCCOPPE/UFRJ



# Do que trata Redes Complexas?



- ❑ Entender como as coisas se conectam e as consequências desta conectividade

“Coisas que se conectam” → **Redes**

“Como, por que, e consequências” → **Complexo**

- ❑ **Estrutura** assume papel central
  - necessária para compreender fenômenos que ainda não explicamos
- ❑ A rede não é complexa!

# Organização do Mini-curso

- ❑ Três encontros (Qui 17h, Sex 11h, Sex 17h)
  - duas horas cada, brinde na Sex 17h
- ❑ **Encontro 1**
  - Redes por todos os lados, formalismo e propriedades, descobrimentos empíricos
- ❑ **Encontro 2**
  - Lei de potência, modelos de redes:  $G(n,p)$ , Barabási-Albert, Watts-Strogatz, propriedade dos modelos
- ❑ **Encontro 3**
  - Funcionalidade em redes: robustez, busca e navegabilidade

**Interatividade com participação do público!**

# Abaixo a Democracia



- Graus dos vértices é muito desigual
- Muitos com grau pequeno, poucos muito grande
- Ex. média 10, mas valores 100, 1000 e 1000 fazem parte da população

**Modelo matemático que captura esta característica?**

- Distribuição de lei de potência
- Probabilidade não desprezível de ter um elemento muito diferente da média

# Lei de Potência

- Qualquer função que tenha a forma

$$f(x) \sim c x^a$$

c e a são constantes qq  $> 0$

- $f(x)$  evolui de acordo com uma potência
  - lei de potência! (ou polinômio com grau real)
- Relação ocorre quando  $x$  grande

$$f(x) \sim g(x) \longrightarrow \frac{f(x)}{g(x)} \rightarrow 1 \quad \text{quando } x \rightarrow \infty$$

# Distribuição de Lei de Potência

- Lei de potência aplicada a distribuição de probabilidade

$$f_X(x) \sim c x^{-a} \leftarrow \text{expoente negativo, } a > 0$$

- onde  $X$  é uma v.a. e  $f_X(x)$  sua função de probabilidade
- $X$  pode ser discreta ou contínua, limitada ou ilimitada superiormente
- *Cauda pesada*
  - valores grandes podem ocorrer com prob. não desprezível

# Distribuição Zeta

- Seja  $X$  uma v.a. discreta ilimitada superiormente
- $X$  assume valores  $1, 2, \dots$

$$p_k = P[X = k] \sim k^{-a}$$

- Determinar constante  $c$  de normalização

$$p_k = c k^{-a}$$

- Temos então

$$\sum_{k>0} p_k = 1 \longrightarrow c = 1 / \sum_{k>0} k^{-a} = 1 / z(a)$$

# Função Zeta de Riemann

- $\zeta(a)$  é a função zeta de Riemann

$$\zeta(a) = \sum_{k>0} k^{-a}$$

- Problema: determinar quando  $\zeta(a)$  converge
- Se  $\zeta(a)$  não converge,  $p_k$  não é função de probabilidade (não temos como normalizar)
- Converte para qualquer  $a > 0$  ?

**Converge apenas para  $a > 1$**



# Momentos da Zeta

- Calcular momentos da distribuição zeta
- Cola: n-ésimo momento é dado por  $E[X^n]$
- Primeiro momento é valor esperado

**Idéias???**

- Aplicar definição

$$E[X^n] = \sum_{k>0} k^n p_k$$

# Momentos da Zeta

- n-ésimo momento é dado por

$$E[X^n] = z(a-n) / z(a)$$

Converge sempre?

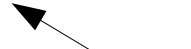
- para  $a - n > 1$  ou seja,  $a > n + 1$
- infinito caso contrário (não converge)
- Exemplo:  $a = 2.3$ ,  $E[X]$  existe?  $\text{Var}[X]$  existe?
- Cola:  $\text{Var}[X] = E[X^2] - E[X]^2$
- Muitas redes tem expoente  $2 < a < 3$

# Invariância em Escala

- Propriedade “scale free”
- Multiplicar o argumento por  $k$  mantém a forma de  $f$

$$f(bk) \sim c(bk)^{-a} \sim b^{-a} ck^{-a} = b^{-a} f(k)$$

constante depende apenas de  $k$



- A forma é preservada independente da escala
- Ex.  $a = -2$ ,  $k = 3$ 
  - evento 3 vezes maior tem 9 vezes menos probabilidade de ocorrer, independente do tamanho do evento!

# Escala log-log

- Aplicar logaritmo aos dois lados da equação

$$f(k) \sim c k^{-a}$$

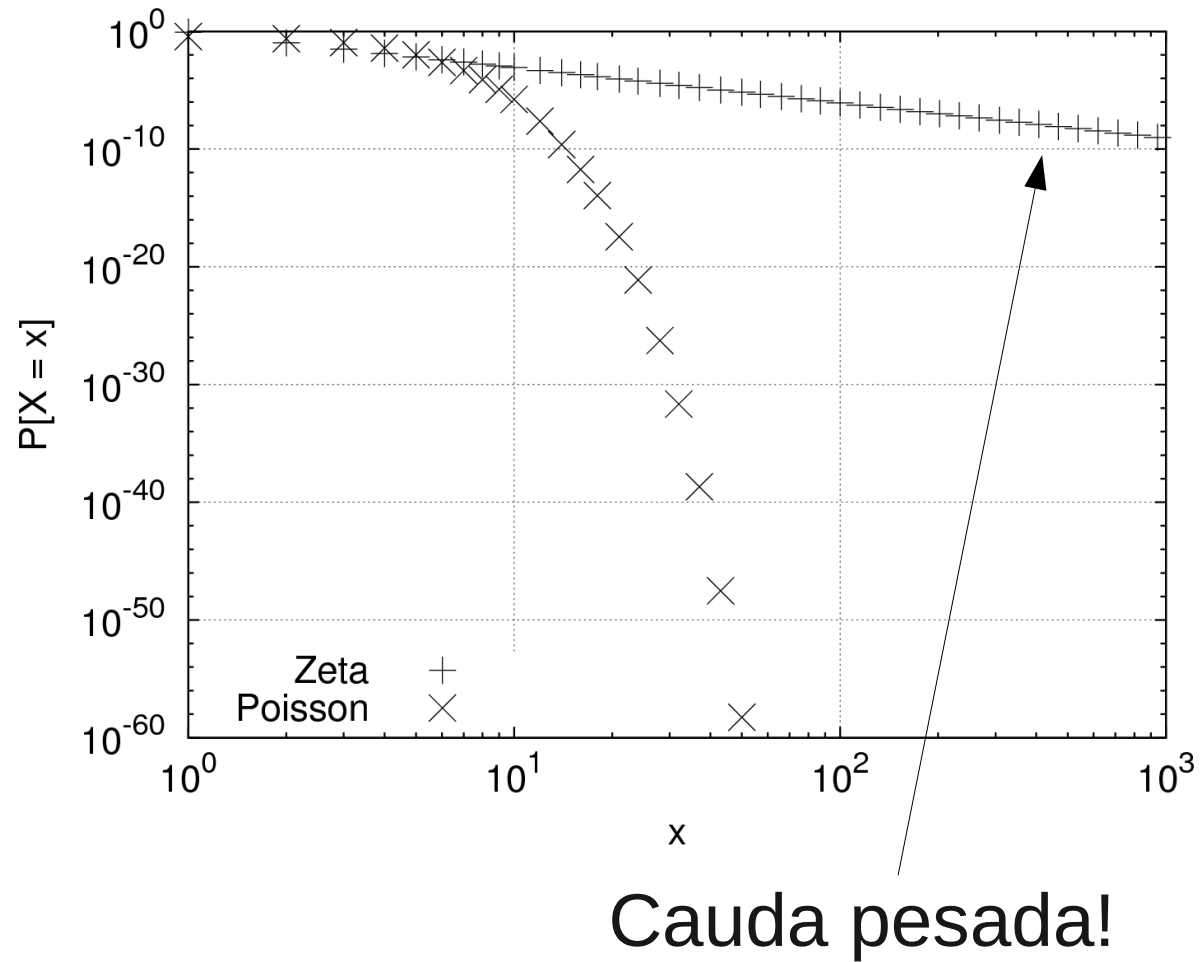
- Temos então

$$\log(f(k)) \sim \log(c k^{-a}) = -a \log k + \log c$$

- Relação linear entre  $\log f(k)$  e  $\log k$  com inclinação  $-a$
- Expoente determina inclinação da reta
- Invariância na escala
  - inclinação não depende de  $k$

# Exemplo

- Comparação entre Zeta ( $a = 3$ ) e Poisson
- Mesmo valor esperado
- Poisson tem cauda exponencial
- Zeta pode gerar valores  $10^{50}$  mais chance!



# Distribuições em Lei de Potência

## Zipf

- Variação de distribuição de Zeta
- Valores de  $X$  são limitados superiormente
- Momentos sempre existem (para qualquer expoente)

## Pareto

- Variável aleatória contínua (Zeta e Zipf são discretas)
- Pode ser ou não limitada superiormente
- Aproximação contínua para fenômenos discretos (ex. grau)

# Estudando Redes Reais



- Como estudar de forma generalizada uma rede real?
  - ex. Internet, Facebook

## **Modelo matemático!**


- Abstração matemática da realidade
- Permite trabalhar analiticamente com realidade simplificada
  - vai além do estudo empírico da realidade

## **Modelo matemático para redes**


# Modelos Determinísticos para Redes

- Estrutura topológica é determinística
- Propriedades e características topológicas são determinísticas


## Exemplos de modelos?



Grafo Kneser



Hiper cubo




Grafos de Caley




# Modelos Probabilísticos para Redes

- Estrutura topológica é aleatória
  - definido através de um processo aleatório


## Exemplos de modelos?



Erdős-Rényi



Watts-Strogatz



Barabási-Albert

# Modelo $G(n,p)$




- Modelo clássico para grafos aleatórios
  - introduzido por Erdős e Rényi na década de 50
  - aka. modelo binomial, modelo de Erdős-Rényi

## Como funciona o modelo?

- Grafo possui  $n$  vértices rotulados
- Cada possível aresta do grafo existe com probabilidade  $p$  independentemente
  - grafo não-direcionado, sem loops

# Modelo $G(n,p)$

- Modelo possui dois parâmetros (determinísticos)
  - $n$ : número de vértices
  - $p$ : prob. de existência de cada aresta
- Dado os dois parâmetros, grafo gerado é único?
  - Ex.  $n=5$ ,  $p=0.5$
- Não! Grafo é aleatório, será amostrado



# Estudo do $G(n,p)$

- Estudar a **estrutura** do modelo  $G(n,p)$ 
  - em função de  $n$  e  $p$  (únicos parâmetros)
- Estrutura é aleatória
  - depende da realização
- Estrutura depende de  $n$  e  $p$ 
  - efeitos de borda quando  $n$  é pequeno
- Caracterizar estrutura para  $n$  muito grande
  - estrutura quando  $n$  tende para infinito

**Como caracterizar a estrutura?**

# Propriedades Simples

- Espaço amostral do modelo  $G(n,p)$ ?
  - Quantos grafos diferentes?

$$|S| = 2^{\binom{n}{2}} \longleftarrow \text{Cada aresta pode ou não estar presente}$$

- Probabilidade do modelo gerar um grafo  $G$  específico com  $n$  vértices?
  - Gerar um conjunto de arestas  $E = \{e_1, e_2, \dots, e_m\}$

$$P(\text{gerar conjunto } E) = p^{|E|} (1-p)^{\binom{n}{2} - |E|}$$

- Depende apenas de  $|E|$
- Todos grafos são equiprováveis quando  $p = 1/2$

# Arestas do $G(n,p)$

- Quantas arestas tem um grafo do modelo  $G(n,p)$ ?
- Variável aleatória,  $M$ . Distribuição de  $M$ ?

$$P(M = m) = \binom{\binom{n}{2}}{m} p^m (1-p)^{\binom{n}{2} - m}$$


Distribuição binomial

- Valor esperado de  $M$ ?

$$E[M] = \binom{n}{2} p = \frac{n(n-1)p}{2}$$

# Grau do $G(n,p)$

- Qual é o grau de um vértice qualquer do modelo?
- Variável aleatória  $D$ . Distribuição de  $D$ ?



$$P[D = k] ? \quad k = 0, 1, \dots, n-1$$

- Cada aresta incide sobre vértice  $i$  com prob  $p$

$$P[D = k] = \binom{n-1}{k} p^k (1-p)^{n-1-k}$$

← Distribuição binomial

- Valor esperado do grau?

$$E[D] = (n-1)p$$

# Coeficiente de Clusterização

- De um vértice qualquer (escolhido ao acaso)
- Variável aleatória,  $K$ . Distribuição? Valor esperado?
- Distribuição condicional, no grau do vértice

$$P\left[ K = \frac{k}{\binom{d}{2}} \mid D = d \right]$$

← Prob. de termos  $k$  arestas entre os  $d$  vizinhos do vértice

- Valor esperado

$$E[K] = p$$

← Não depende do grau



# Propriedades Topológicas

- Seja propriedade  $X$ 
  - ex.  $X = \text{“grafo é conexo”}$
- Seja  $G$  um grafo decorrente da realização do processo aleatório
  - $G$  é uma amostra do modelo

**$G$  possui propriedade  $X$ ?**

- Subconjunto do espaço amostral possui propriedade  $X$
- $G$  possui  $X$  probabilisticamente

# Propriedades Topológicas

- Seja  $p_G$  a probabilidade do modelo gerar o grafo  $G$ 
  - grafo  $G$  é determinístico, uma amostra
- Seja  $C$  o conjunto de grafos (determinísticos) que possuem propriedade  $X$
- Então temos

$$P[G \text{ possuir } X] = \sum_{G' \in C} p_{G'}$$

- Probabilidade pode depender de  $n$ 
  - número de vértices do grafo
- Interesse na probabilidade assintótica
  - quando  $n$  é muito grande

# Propriedade de Quase Todos os Grafos

- Seja  $G$  um modelo aleatório para grafos e  $X$  uma propriedade topológica

- Se

$$P[G \text{ possuir } X] \rightarrow 1 \quad \text{quando } n \rightarrow \infty$$

- Então dizemos que quase todos os grafos de  $G$  possuem  $X$ 
  - $X$  ocorre em  $G$  a.a.s. (*asymptotically almost surely*)
- Análogo quando probabilidade tende a zero
  - $X$  nunca ocorre em  $G$  a.a.s.

# Comportamento de $p$

- Caracterizar  $G(n,p)$  quando  $n$  tende a infinito. Mas  $p$ ?

**Como  $p$  varia quando  $n \rightarrow \infty$**

- Duas alternativas
  - $p$  é fixo, não varia
  - $p$  é uma função de  $n$ , varia com  $n$
- Influência fundamental na estrutura
  - estrutura depende de  $p$

# $G(n,p)$ com $p$ fixo

- Considere  $p > 0$  fixo (constante)
- Grau esperado dos vértices?
  - quando  $n$  tende a infinito?
- Número esperado de arestas no grafo?
  - quando  $n$  tende a infinito?

## Grafo muito denso

- **Intuitivamente:** Grafo conexo, vértices muito próximos

# $G(n,p)$ com $p$ fixo

- Para  $p$  constante  $> 0$ ,  $G(n,p)$  é conexo a.a.s.
- Para  $p$  constante  $> 0$ ,  $G(n,p)$  possui diâmetro 2 a.a.s.
- Podemos provar estas propriedades
  - bom exercício
- $G(n,p)$  com  $p$  fixo não é muito interessante

# G(n,p) com p(n)

- p(n) é uma função de n
  - caso anterior p(n) = cte

## Qual p(n)?

- p(n) deve **decrecer** com n
  - Figura!
- Exemplos

$$p(n) = \frac{c}{n}$$

$$p(n) = n^{-2.5}$$

$$p(n) = \frac{c \log n}{n}$$

# G(n,p) com grau médio fixo

- Grau médio fixo, igual a  $z$

$$p(n) = z / (n - 1)$$

- Propriedades estruturais dependem de  $z$ 
  - estudo em função de  $z$
- Tamanho das componentes conexas

**Intuição?**

- Divisor de águas:  $z < 1$ ,  $z > 1$  ?



# Componentes Conexas

- $z$  : grau médio de um vértice
- $z < 1$  (subcrítico)
  - componentes conexas tem tamanho  $O(\log n)$  (a.a.s.)
  - Muitas componentes conexas
- $z > 1$  (supercrítico)
  - maior componente conexa tem tamanho  $\Omega(n)$
  - todas outras de tamanho  $O(\log n)$

**Transição de fase na estrutura do grafo!**

# Adequação do Modelo $G(n,p)$

- O quão adequado é o modelo  $G(n,p)$  para representar redes reais?

**Captura número de vértices e grau médio!**

- Suficiente?
- Depende dos objetivos...

**Captura outros aspectos estruturais das redes reais?**

# Aspectos Estruturais

- Presente em muitas redes reais
  - Distâncias pequenas
  - Alta clusterização
  - Distribuição do grau segue lei de potência
- Modelo  $G(n,p)$ 
  - Distâncias:  $O(\log n / \log z)$
  - Clusterização:  $p$
  - Distribuição do grau: Binomial( $n-1, p$ )

**Muito diferentes!**



**Aspectos fundamentais para muitas aplicações**


# Exemplo

- AS Graph, 10697 vértices e 31992 arestas
  - Distância média
    - empírica: 3.31
    - modelo:  $O(\log n / \log z) = 5.18$
  - Clusterização
    - empírica: 0.39
    - modelo:  $p = 0.00056$
- ~1000 vezes menor!**


# Exemplo

- AS Graph, 10697 vértices e 31992 arestas
- Distribuição do grau:  $P[D > k]$

Empírica



Modelo  $G(n,p)$



**Fundamentalmente diferente!**

# Modelos Generativos

- Explicam o surgimento das propriedades estruturais
  - estrutura é função do processo gerador
- Vértices e arestas são adicionados incrementalmente
  - refletem o “crescimento” da rede
- Processo de crescimento tenta capturar a realidade
  - processo gerador leva a estrutura observada

**Muitos modelos propostos são desta classe**

# Preferential Attachment (PA)

- Regra fundamental (e antiga) de formação
- **Idéia:** objetos novos têm preferência em se relacionar com objetos mais populares

$$P[u \sim v] \approx pop_v \longleftarrow \text{prob. de novo objeto } u \text{ se relacionar com objeto } v$$

- Objetos populares “atraem” novos objetos
- Idéia possui muitas aplicações
  - objetos e popularidade depende da aplicação

**Exemplos ?**

# Modelo para Redes

- Modelo para grafos (redes) aleatórias baseado em PA (Barabasi et al 99)
  - objetos são vértices e popularidade é dada pelo grau do vértice
- Processo de formação
  - Inicialmente temos pequeno clique
  - a cada passo, adicionar 1 vértice com grau  $m$
  - vértice adjacente é escolhido aleatoriamente, com prob. proporcional ao seu grau




# PA Exemplo



- Clique inicial com 3 vértices,  $m = 2$
- Tamanho do vértice proporcional ao grau

# PA Exemplo



- O que está acontecendo?
- “*Rich gets richer*” -> Lei de potência?

# Definindo Preferências

- Dado grafo  $G=(V, E)$  no instante  $t = 1, 2, \dots$
- $d_u(t)$ : grau do vértice  $u$  no instante  $t$
- Considere a chegada de um novo vértice no instante  $t$ 
  - vértice traz  $m$  arestas
- $p_u(t)$ : prob. do vértice  $u$  ser incidente a uma nova aresta no instante  $t$

$$p_u(t) = \frac{d_u(t)}{\sum_{v \in V} d_v(t)} = \frac{d_u(t)}{2mt} \quad \leftarrow \text{número de arestas do grafo em } t$$

# Evolução do Grau do Vértice

- Quanto vale  $d_u(t)$  ?
  - $d_u(t)$  é uma v. a. discreta
- Assumir  $d_u(t)$  é determinístico (valor esperado) e contínuo
- Seja  $t_u$  o instante de entrada do vértice  $u$
- Podemos mostrar

$$d_u(t) = m \left( \frac{t}{t_u} \right)^{1/2}$$

- Grau de um vértice cresce como lei de potência
- Mais antigos tem grau maiores

# Distribuição do Grau

- Distribuição do grau no tempo  $t$ 
  - distribuição depende to tempo?

$$P[d_u(t) < k]$$

- Assumir que instante de chegada é uniforme
  - Vértices  $u$  entra entre  $[1, t]$
- Podemos mostrar:

$$P[d_u(t) = k] \approx \frac{2m^2}{k^3} \longleftarrow \text{Lei de potência na distribuição do grau}$$

# Observação sobre PA

- Fenômenos observados podem ser modelados por PA
- Modelo pode levar ao surgimento de *lei de potência* na popularidade dos objetos
- PA como *explicação* para leis de potência observadas empiricamente
  - lei de potência surge, pois processo de formação obedece ao PA
- **Cuidado:** nem toda lei de potência é explicada por PA

# Limitação do Modelo BA

- Lei de potência com expoente 3
  - muitas redes tem outros expoentes
- Vértices mais antigos tem grau maiores
  - vértices novos não tem chance de serem populares
- Vértices criam arestas somente no instante de chegada
  - não há evolução local da rede
- Rede gerada tem baixa clusterização

# Modelo Small World

- Inspirado nos resultados de Milgram
- Inspirado na alta clusterização observada empiricamente
  - proposto por Watts and Strogatz (Matemática Aplicada) em 1998
  - 30 anos depois de Milgram!
  - Início de “Redes Complexas”
- Modelo captura as duas propriedades
- Mostra que ambas podem coexistir em um mesmo grafo esparso



# Clusterização e Distâncias


- Considere um grafo esparso
  - número de arestas relativamente pequeno
- Considere alta clusterização e caminhos curtos

## Propriedades Antagônicas?

- **Alta clusterização:** muitos triângulos, arestas “desperdiçadas”, caminhos não avançam
- **Caminhos curtos:** arestas usadas eficientemente, avanço mais rápido

# Modelo Small World

- Começar com um látice regular
  - $N$  vértices organizados em um círculo
  - arestas para os  $K$  vizinhos mais próximos



- Para cada aresta, reposicionar suas extremidades com probabilidade  $p$ 
  - nova extremidade escolhida de maneira uniforme entre os vértices

# Propriedades Estruturais

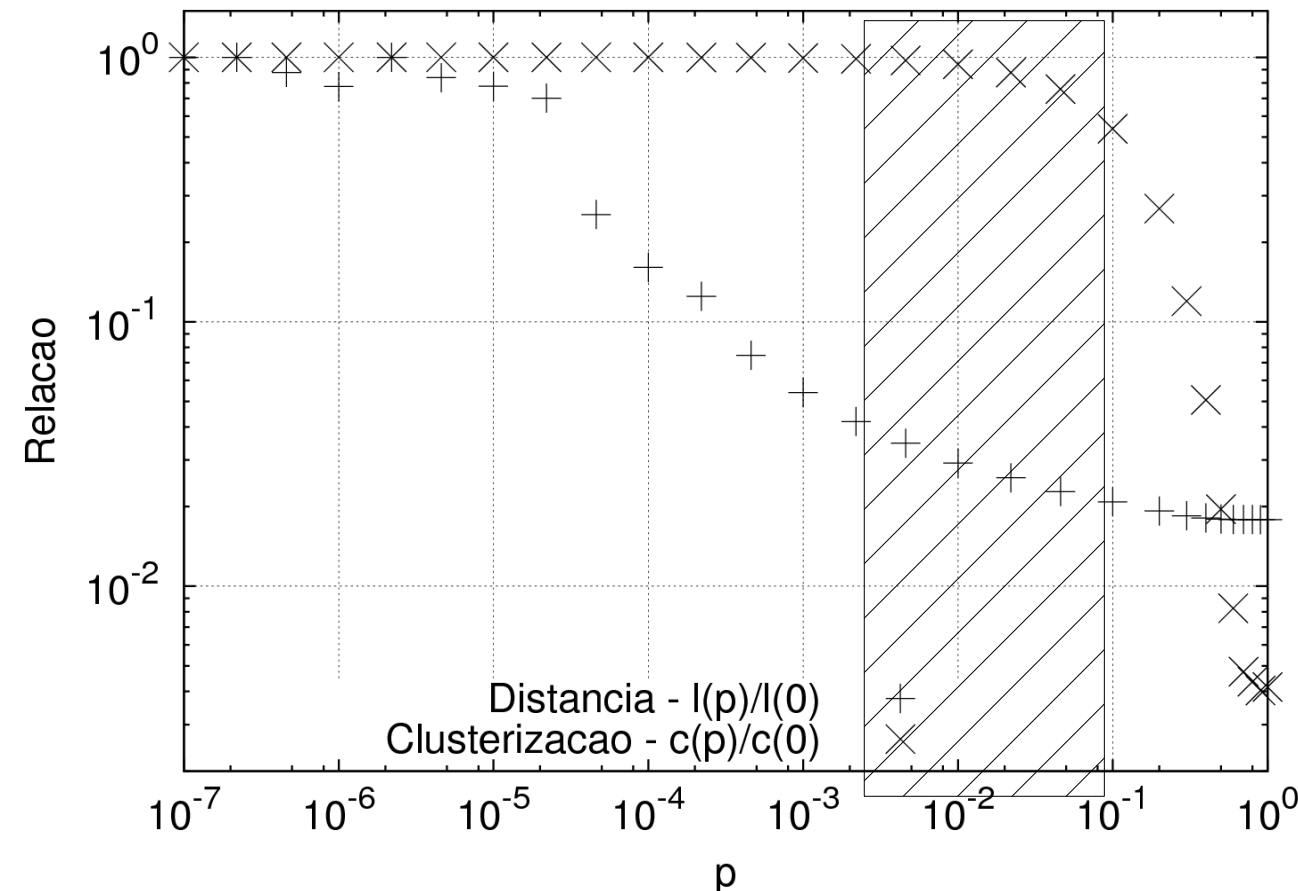
- Considere  $n$  grande,  $k$  grande, com  $n \gg k$
- $C(p)$  : clusterização em função de  $p$ 
  - $C(0)$ , alta clusterização (intuitivamente)
  - $C(1)$ , baixa clusterização
- $I(p)$  : distância média em função de  $p$ 
  - $I(0)$ , distância média alta (intuitivamente)
  - $I(1)$ , distância média baixa

**O que ocorre quando  $p$  é intermediário?**

# Análise Numérica

- Relação entre  $C(p)/C(0)$  e  $l(p)/l(0)$

- $C(0)$  maior clusterização,  $l(0)$  maior distância média



- Distância média decresce rapidamente
- Clusterização decresce mais devagar
- Alta clusterização, distâncias curtas é possível!
- Small World Networks

# Limitação do Modelo SW

- Distribuição de grau não possui cauda pesada
- Não representa um fenômeno real para criação da rede
  - Não possui crescimento



- Muitos outros modelos surgiram na última década
- Modelos que capturam função da rede (e do domínio)
- Problema ainda em aberto