

# Redes Complexas

## Aula 3

### Aula passada

- Caracterizando redes grandes
- Grau
- Distâncias
- Clusterização
- Características de redes reais

### Aula de hoje

- Centralidade de vértices
- *Betweeness, Closeness*
- Centralidade de Autovetor, Katz, PageRank

# Centralidade



## Como medir a *importância* de um vértice?

- Utilizando apenas a estrutura
- Relativo a outros vértices
  - Métricas locais
    - dependem apenas da vizinhança do vértice  
(Ex. grau, random walk)
  - Métrica globais
    - Dependem do grafo inteiro  
(Ex. Closeness, pagerank)
- Grau
- Betweeness
- Closeness
- Autovetor
- Random walks
- etc.

# Centralidade



**Qual é a melhor métrica  
de importância?**

- Como determinar a qualidade do ranqueamento produzido?

**Impossível sem referência externa!**

- Referência externa para avaliar ranqueamento
  - empírica ou processual
- Referência depende do contexto e do objetivo do ranqueamento

**Não existe a melhor métrica!**

# Centralidade de Grau

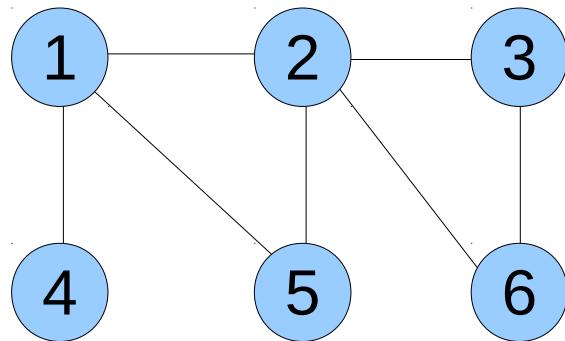
- Grau do vértice ou grau do vértice normalizado
  - valor entre 0 e 1

$$C_v = \frac{d_v}{n-1}$$

- Grafo direcionado, grau de entrada/saída
  - duas centralidades em grau por vértice

# Centralidade de Betweenness

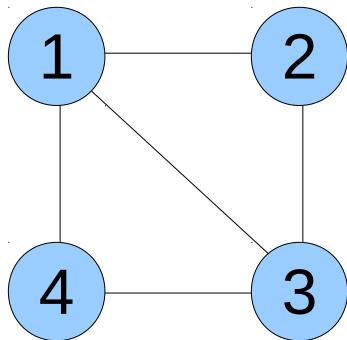
- Mede o quanto no “meio do caminho” um vértice está
- Considerar todos os caminhos mínimos do grafo
- Número de caminhos mínimos que passam pelo vértice
- Exemplo



- Grafo completo,  $K_n$  ?
- Grafo estrela, com  $n$  folhas?

# Centralidade de Betweenness

- **Problema:** Como definir métrica quando mais de um caminho mínimo existe entre um par origem/destino?
  - empate no custo do caminho mínimo
- Exemplo



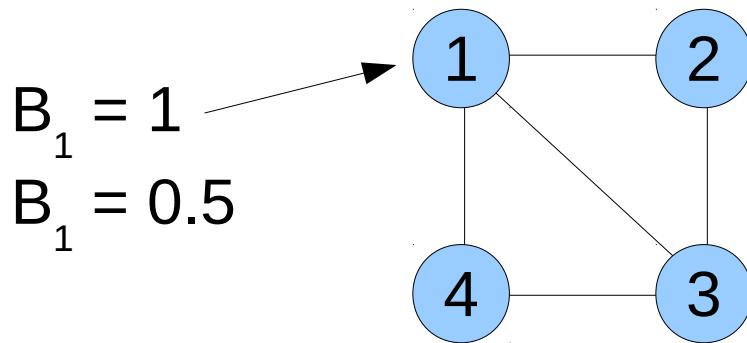
- Caminho mínimo entre 2 e 4?
- 2,1,4 ou 2,3,4?
- Centralidade do vértice 1 e 3?

# Centralidade de Betweenness

- Duas abordagens

- Cada caminho mínimo conta 1 vez
  - “Carga” dividida pelos caminhos mínimos (cada caminho mínimo conta  $1/k$  para a métrica, para  $k$  caminhos)

- Exemplo



- Para muitas redes, diferença é pequena
  - Mas nem sempre!

# Calculando Betweeness

- Mais precisamente

$$C_v = \sum_{s, t \in V; s, t \neq v} \frac{\sigma_v(s, t)}{\sigma(s, t)}$$

Número de caminhos  
mais curtos entre s e t  
que passam por v

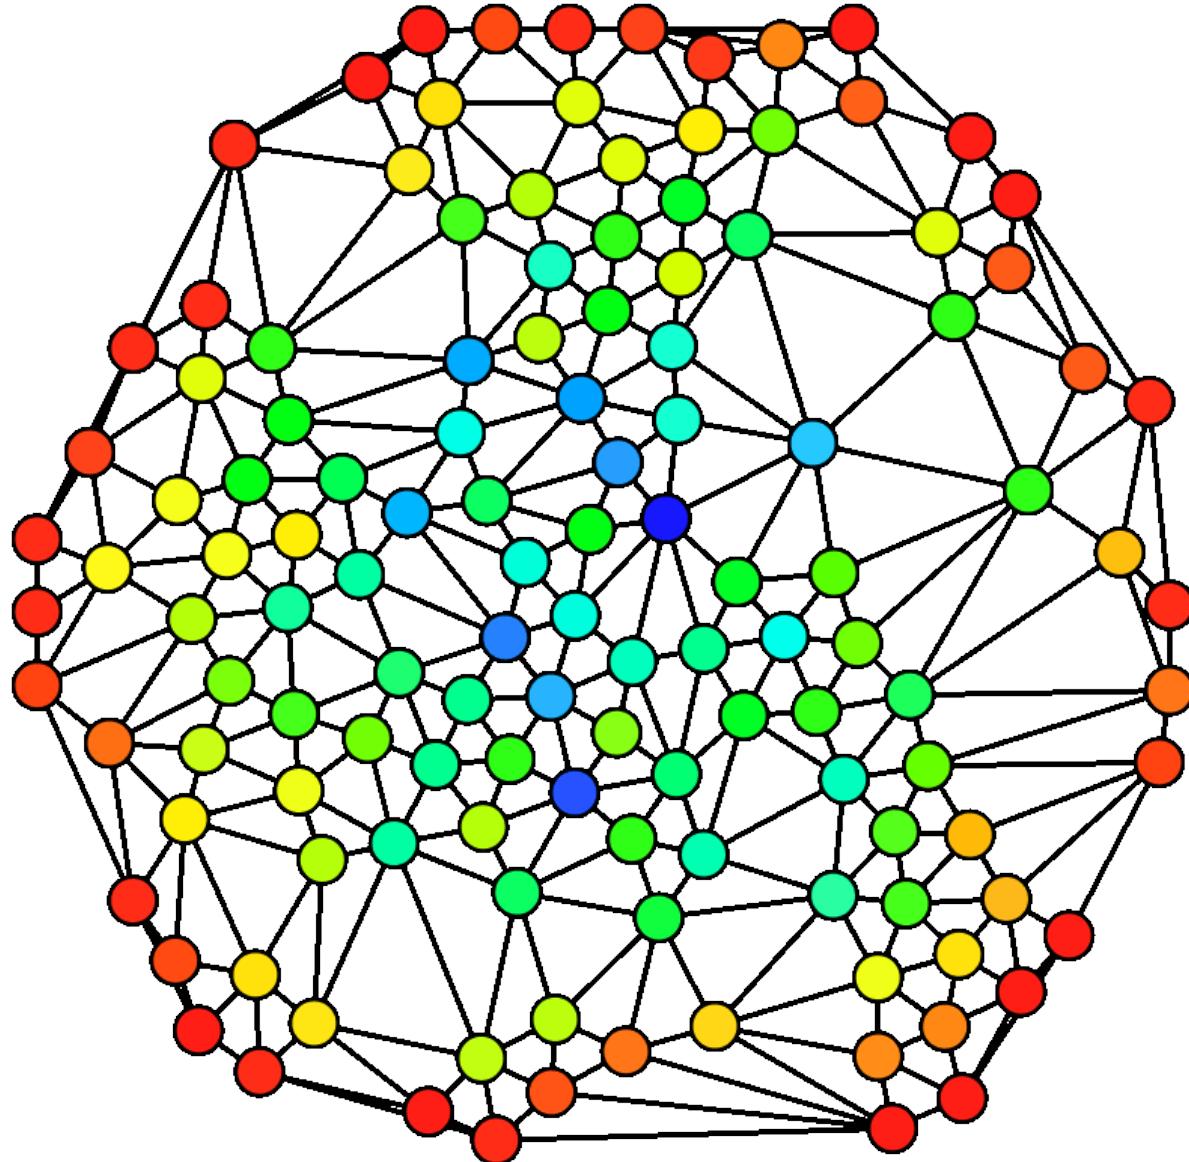
- ou

$$C_v = \sum_{s, t \in V} \sigma_v(s, t)$$

Número de caminhos  
mais curtos entre s e t

- Pode ser normalizada pelo número total de pares origem/destino (sem contar v)
  - métrica entre 0 e 1

# Exemplo



- Cores indicam betweeness
- Vermelho = 0, azul = máximo
- Ilustra vértices mais centrais

# Centralidade de Closeness

- Utiliza conceito de distância
  - com ou sem pesos
- Distância média entre vértice e o resto do grafo
  - capturar o quanto central é o vértice

$$C_v = \frac{\sum_{t \in V - \{v\}} d(v, t)}{n-1}$$

- “Velocidade” com a qual informação se propaga de um vértice para o resto da rede

# Centralidade de Closeness

- Maior distância a qualquer outro vértice do grafo
  - eccentricidade (*eccentricity*) do vértice

$$C_v = \max_{t \in V - \{v\}} d(v, t)$$

# Centralidade

- **Ideia:** importância do vértice depende da importância dos vizinhos
  - Recursão *to the rescue!*

**Como formalizar ideia?**

- Seja  $x_i$  a importância do vértice  $i$

$$x_i = \sum_{j=1}^n a_{ij} x_j$$

Somatório da importância  
dos vizinhos de  $i$   
 $a_{ij}$ : matriz de adjacência

**Como calcular  $x_i$ ?**

# Centralidade de Autovetor

- Processo iterativo
- Iniciar com  $x(0) = (x_1(0), \dots, x_n(0))$
- Forma matricial:  $x(1) = Ax(0)$
- Depois de  $t$  iterações:

$$x(t) = A^t x(0)$$

**Processo converge!**  
**(normalizar  $x$  depois de cada passo)**

$$Ax = \kappa_1 x \quad \longleftarrow \quad x \text{ é o autovetor associado ao autovalor } k_1 \text{ (maior autovalor)}$$

# Redes Direcionadas

**Como definir importância?**

- **Ideia:** importância do vértice depende da importância dos vértices que apontam para ele

$$x_i = \sum_{j=1}^n a_{ji} x_j \leftarrow a_{ij} \neq a_{ji}$$

**Problema?**

- Vértices com grau de entrada zero?
- Zero em todos os vértices fora da CC

# Centralidade de Katz

## Como resolver o problema?

- **Idéia:** Todo vértice tem pequena importância intrínseca

$$x_i = \alpha \sum_{j=1}^n a_{ij} x_j + \beta \quad \leftarrow \begin{array}{l} \text{alpha e beta não} \\ \text{dependem da estrutura} \end{array}$$

- Relação entre alpha e beta determina relação entre estrutura e aptidão externa
  - em geral beta = 1
- Centralidade de Katz

# Centralidade de Katz

**Qual valor para alpha?**

$$x_i = \alpha \sum_{j=1}^n a_{ij} x_j + 1$$

- Alpha muito pequeno, centralidade dado por beta (1)
- Alpha muito grande, processo iterativo diverge
- Restrição para convergência:

$$\alpha < 1/\kappa_1 \quad \longleftarrow \text{maior autovalor de } A$$

# Centralidade de PageRank

## Problema com Katz?

- Vértice importantes espalham importância igualmente, independente do grau de saída
- Melhor intuição: espalhar importância proporcionalmente

$$x_i = \alpha \sum_{j=1}^n a_{ji} \frac{x_j}{d_j} + \beta$$

← Grau de saída de j

- Centralidade de PageRank, com  $\beta=(1-\alpha)/N$
- Proposta e utilizada pelo Google

# PageRank

- Interpretação original: surfista passeando pela Web de forma aleatória (*random surfer model*)
  - a cada página, escolhe hiperlink de maneira uniforme
- Importância: fração de visitas a cada página

**Problema: Web não é conexa!**

- Surfista dá saltos para qualquer página da web
  - a cada página, decide dar saltos aleatórios
- Solução é dada pelas equações do slide anterior!

**Modelo é uma cadeia de Markov!**

# Personalized PageRank

- PageRank: ranqueamento absoluto dos vértices da rede
- Como obter ranqueamento relativo a um vértice?
  - importância do ponto de vista do vértice

## Personalized PageRank (PPR)

- **Ideia:** retorno (salto) não é uniforme, mas sim para um vértice específico
  - difusão a partir deste vértice ( $i^*$ )

$$x_i = \alpha \sum_{j=1}^n a_{ji} \frac{x_j}{d_j^s} + \beta \leftarrow \begin{array}{ll} \beta = (1-\alpha), & \text{se } i = i^* \\ \beta = 0, & \text{se } i \neq i^* \end{array}$$

## Rankeamento relativo a $i^*$