

# Introdução às Redes de Interação – MO804 (MC908)

## Homofilia, Modularidade e Detecção de Comunidades

Prof. Dr. Ruben Interian

Instituto de Computação, UNICAMP

# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração
- 3 Modularidade
- 4 Detecção de comunidades
- 5 Aplicações

# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração
- 3 Modularidade
- 4 Detecção de comunidades
- 5 Aplicações

# Homofilia

**Homofilia** – tendência dos vértices de ter vínculos com outros vértices semelhantes.

# Homofilia

**Homofilia** – tendência dos vértices de ter vínculos com outros vértices semelhantes.

## O que é “semelhantes”?

- Representação **mais fácil**: dois vértices são “semelhantes” se pertencem ao mesmo grupo.
- **Outras** representações: cada nó possui um vetor de atributos, podemos usar a “similaridade” entre estes vetores.

# Homofilia

**Homofilia** – tendência dos vértices de ter vínculos com outros vértices semelhantes.

## O que é “semelhantes”?

- Representação **mais fácil**: dois vértices são “semelhantes” se pertencem ao mesmo grupo.
- **Outras** representações: cada nó possui um vetor de atributos, podemos usar a “similaridade” entre estes vetores.

## Como avaliar a homofilia em uma rede real?

- Para **um vértice**?
- Para **a rede inteira**?

# Homofilia

Como avaliar a **homofilia de um vértice**?

# Homofilia

Como avaliar a **homofilia de um vértice**?

- Seja  $G = (V, E)$  um grafo, e seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós que formam uma partição do conjunto  $V$ .

# Homofilia

Como avaliar a **homofilia de um vértice**?

- Seja  $G = (V, E)$  um grafo, e seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós que formam uma partição do conjunto  $V$ .
- A homofilia de um nó  $v$  pode ser definida como a razão  $h(v) = \frac{d_i(v)}{d(v)}$  entre o número de vizinhos de  $v$  que estão no seu grupo, e o grau de  $v$ .

# Homofilia

## Como avaliar a **homofilia de um vértice**?

- Seja  $G = (V, E)$  um grafo, e seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós que formam uma partição do conjunto  $V$ .
- A homofilia de um nó  $v$  pode ser definida como a razão  $h(v) = \frac{d_i(v)}{d(v)}$  entre o número de vizinhos de  $v$  que estão no seu grupo, e o grau de  $v$ .
- Se os grupos não influenciam na estrutura de arestas, então  $h(v) \approx \frac{|A_i|}{|V|} = w_i$  é o valor **esperado** para  $h(v)$ .

# Homofilia

## Como avaliar a **homofilia de um vértice**?

- Seja  $G = (V, E)$  um grafo, e seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós que formam uma partição do conjunto  $V$ .
- A homofilia de um nó  $v$  pode ser definida como a razão  $h(v) = \frac{d_i(v)}{d(v)}$  entre o número de vizinhos de  $v$  que estão no seu grupo, e o grau de  $v$ .
- Se os grupos não influenciam na estrutura de arestas, então  $h(v) \approx \frac{|A_i|}{|V|} = w_i$  é o valor **esperado** para  $h(v)$ .
- Qual deve ser a **diferença** entre  $h(v)$  e  $w_i$  para que possamos afirmar que há homofilia? – Analisamos a significância estatística de ter  $d_i(v)$  adjacentes do mesmo grupo dentre os  $d(v)$  adjacentes.

# Homofilia

Como avaliar a **homofilia da rede inteira?**

# Homofilia

Como avaliar a **homofilia da rede inteira**?

- **Primeira abordagem:** usar a média dos valores de  $h(v)$  de cada vértice. Útil apenas em casos simples.

# Homofilia

Como avaliar a **homofilia da rede inteira**?

- **Primeira abordagem**: usar a média dos valores de  $h(v)$  de cada vértice. Útil apenas em casos simples.
- **Abordagem um pouco melhor**: avaliar quão longe está a quantidade de arestas entre vértices de diferentes grupos do valor esperado.

# Homofilia

Como avaliar a **homofilia da rede inteira**?

- **Primeira abordagem**: usar a média dos valores de  $h(v)$  de cada vértice. Útil apenas em casos simples.
- **Abordagem um pouco melhor**: avaliar quão longe está a quantidade de arestas entre vértices de diferentes grupos do valor esperado.
- Se uma aresta é colocada **aleatoriamente** no grafo, então a chance de:
  - Escolher dois vértices de  $X$  é  $w_x^2$ , e escolher dois vértices de  $Y$  é  $w_y^2$ .
  - Escolher vértices de grupos diferentes é  $2w_x w_y$ .

# Homofilia

Como avaliar a **homofilia da rede inteira**?

- **Primeira abordagem**: usar a média dos valores de  $h(v)$  de cada vértice. Útil apenas em casos simples.
- **Abordagem um pouco melhor**: avaliar quão longe está a quantidade de arestas entre vértices de diferentes grupos do valor esperado.
- Se uma aresta é colocada **aleatoriamente** no grafo, então a chance de:
  - Escolher dois vértices de  $X$  é  $w_x^2$ , e escolher dois vértices de  $Y$  é  $w_y^2$ .
  - Escolher vértices de grupos diferentes é  $2w_x w_y$ .
- Se a proporção de arestas intra-grupo é significativamente **maior** do que  $w_x^2 + w_y^2$ , então **há evidência** de homofilia.


# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração**
- 3 Modularidade
- 4 Detecção de comunidades
- 5 Aplicações

# Homofilia *revisited*

## Revisitando a homofilia.

- Quantas arestas inter-grupo e intra-grupo há na rede?




# Homofilia *revisited*

## Revisitando a homofilia.

- **Quantas arestas inter-grupo e intra-grupo há na rede?**


9 arestas inter-grupo, 3 arestas no grupo azul.



# Homofilia *revisited*

## Revisitando a homofilia.

- **Quantas arestas inter-grupo e intra-grupo há na rede?**  
9 arestas inter-grupo, 3 arestas no grupo azul.
- **Qual é o número esperado dessas arestas se não houvesse homofilia?**



# Homofilia *revisited*

## Revisitando a homofilia.


- **Quantas arestas inter-grupo e intra-grupo há na rede?**

9 arestas inter-grupo, 3 arestas no grupo azul.

- **Qual é o número esperado dessas arestas se não houvesse homofilia?**

$$2w_x w_y = 2 \frac{1}{4} \frac{3}{4} = \frac{3}{8}$$

⇒ o esperado é  $12 \frac{3}{8} = 4.5$  arestas inter-grupo.



# Homofilia *revisited*

## Revisitando a homofilia.

- Quantas arestas inter-grupo e intra-grupo há na rede?

9 arestas inter-grupo, 3 arestas no grupo azul.


- Qual é o número esperado dessas arestas se não houvesse homofilia?

$$2w_x w_y = 2 \frac{1}{4} \frac{3}{4} = \frac{3}{8}$$

⇒ o esperado é  $12 \frac{3}{8} = 4.5$  arestas inter-grupo.

$$w_x^2 = \left(\frac{1}{4}\right)^2 = \frac{1}{16}$$


⇒ o esperado é  $12 \frac{1}{16} = \frac{3}{4}$  arestas no grupo X.



# Homofilia *revisited*

## Revisitando a homofilia.


- O esperado, em um grafo aleatório, é  $\frac{3}{4}$  de aresta no grupo azul. Mas, se temos 2 vértices de grau 5 em um grafo com 12 arestas, qual é a chance deles estarem conectados?...



# Homofilia *revisited*

## Revisitando a homofilia.


- O esperado, em um grafo aleatório, é  $\frac{3}{4}$  de aresta no grupo azul. Mas, se temos 2 vértices de grau 5 em um grafo com 12 arestas, qual é a chance deles estarem conectados?...
- A chance deles **não estarem conectados** é **pequena**. Entre 2 vértices azuis, **é bem mais provável a aresta existir do que não existir!**



# Homofilia *revisited*

## Revisitando a homofilia.

- O esperado, em um grafo aleatório, é  $\frac{3}{4}$  de aresta no grupo azul. Mas, se temos 2 vértices de grau 5 em um grafo com 12 arestas, qual é a chance deles estarem conectados?...
- A chance deles **não estarem conectados** é **pequena**. Entre 2 vértices azuis, **é bem mais provável a aresta existir do que não existir!**
- Vértices de grau maior tem **mais chance de se conectar** do que vértices de grau baixo...  
**Precisamos considerar isso no nosso modelo!**



# Modelo de configuração

Como **modelar corretamente** uma rede aleatória na qual **os graus** dos vértices estão **previamente definidos**?

# Modelo de configuração

Como **modelar corretamente** uma rede aleatória na qual **os graus** dos vértices estão **previamente definidos**?

- Se que cada vértice  $v_i$  na rede tem grau  $d(v_i) = k_i$ , temos:  $\sum_i k_i = 2|E| = 2m$ .


# Modelo de configuração

Como **modelar corretamente** uma rede aleatória na qual **os graus** dos vértices estão **previamente definidos**?

- Se que cada vértice  $v_i$  na rede tem grau  $d(v_i) = k_i$ , temos:  $\sum_i k_i = 2|E| = 2m$ .
- Vamos a associar a cada vértice  $v_i$  uma quantidade  $k_i$  de **objetos** chamados *stubs*, ou **meia-arestas** (metades de arestas).

# Modelo de configuração

Associamos a cada vértice  $v_i$  uma quantidade  $k_i$  de objetos chamados stubs.



# Modelo de configuração

- Podemos escolher um par de **meia-arestas** / **stubs** aleatoriamente dos  $2m$  **stubs**, e por cada par criar uma aresta. Depois, escolhemos **outro par** dentre as  $2m - 2$  meia-arestas restantes, e assim até todos os **stubs** acabarem.

# Modelo de configuração

- Podemos escolher um par de **meia-arestas** / **stubs** aleatoriamente dos  $2m$  **stubs**, e por cada par criar uma aresta. Depois, escolhemos **outro par** dentre as  $2m - 2$  meia-arestas restantes, e assim até todos os **stubs** acabarem.
- O **resultado** é uma rede na qual o **conjunto de arestas** é gerado a partir de um **emparelhamento** dos *stubs*, e cada vértice possui exatamente o grau  $k_i$ .

# Modelo de configuração

- Podemos escolher um par de **meia-arestas** / **stubs** aleatoriamente dos  $2m$  **stubs**, e por cada par criar uma aresta. Depois, escolhemos **outro par** dentre as  $2m - 2$  meia-arestas restantes, e assim até todos os **stubs** acabarem.
- O **resultado** é uma rede na qual o **conjunto de arestas** é gerado a partir de um **emparelhamento** dos *stubs*, e cada vértice possui exatamente o grau  $k_i$ .
- O **modelo de configuração** é o **espaço** (conjunto) **de todos os emparelhamentos**, onde cada um deles tem a mesma chance de aparecer. Cada emparelhamento define um **conjunto de arestas**  $E$ .

# Modelo de configuração

- Podemos escolher um par de **meia-arestas** / **stubs** aleatoriamente dos  $2m$  **stubs**, e por cada par criar uma aresta. Depois, escolhemos **outro par** dentre as  $2m - 2$  meia-arestas restantes, e assim até todos os **stubs** acabarem.
- O **resultado** é uma rede na qual o **conjunto de arestas** é gerado a partir de um **emparelhamento** dos *stubs*, e cada vértice possui exatamente o grau  $k_i$ .
- O **modelo de configuração** é o **espaço** (conjunto) **de todos os emparelhamentos**, onde cada um deles tem a mesma chance de aparecer. Cada emparelhamento define um **conjunto de arestas**  $E$ .
- No modelo de configuração, cada **stub** tem a mesma probabilidade de se conectar a qualquer outro.

# Modelo de configuração

## Outras características do modelo de configuração:

- A rede gerada pode contar **laços** e **arestas múltiplas**.

# Modelo de configuração

## Outras características do modelo de configuração:

- A rede gerada pode contar **laços** e **arestas múltiplas**.
- **Evitar laços e arestas múltiplas leva a problemas!**

# Modelo de configuração

## Outras características do modelo de configuração:

- A rede gerada pode contar **laços** e **arestas múltiplas**.
- **Evitar laços e arestas múltiplas leva a problemas!**
- Felizmente a densidade de laços e arestas múltiplas geradas **tende a zero** quando o número de nós na rede  $n \rightarrow \infty$ , portanto podemos negligenciar esse fato.

# Modelo de configuração

**Probabilidade de uma aresta** entre vértices não isolados  $v_i$  e  $v_j$  no modelo de configuração:

# Modelo de configuração

**Probabilidade de uma aresta** entre vértices não isolados  $v_i$  e  $v_j$  no modelo de configuração:

- **Chance** de um stub específico se conectar com outro stub específico:  $\frac{1}{2m-1}$ .

# Modelo de configuração

**Probabilidade de uma aresta** entre vértices não isolados  $v_i$  e  $v_j$  no modelo de configuração:

- **Chance** de um stub específico se conectar com outro stub específico:  $\frac{1}{2m-1}$ .
- **Chance** de um stub de  $v_i$  se conectar com um dos stubs de  $v_j$ :  $\frac{k_j}{2m-1}$ .

# Modelo de configuração

**Probabilidade de uma aresta** entre vértices não isolados  $v_i$  e  $v_j$  no modelo de configuração:

- **Chance** de um stub específico se conectar com outro stub específico:  $\frac{1}{2m-1}$ .
- **Chance** de um stub de  $v_i$  se conectar com um dos stubs de  $v_j$ :  $\frac{k_j}{2m-1}$ .
- **Chance** de um vértice  $v_i$  com  $k_i$  stubs se conectar com o vértice  $v_j$ :  $\frac{k_i k_j}{2m-1}$ .

# Modelo de configuração

**Probabilidade de uma aresta** entre vértices não isolados  $v_i$  e  $v_j$  no modelo de configuração:

- **Chance** de um stub específico se conectar com outro stub específico:  $\frac{1}{2m-1}$ .
- **Chance** de um stub de  $v_i$  se conectar com um dos stubs de  $v_j$ :  $\frac{k_j}{2m-1}$ .
- **Chance** de um vértice  $v_i$  com  $k_i$  stubs se conectar com o vértice  $v_j$ :  $\frac{k_i k_j}{2m-1}$ .
- **Tecnicamente falando**, o valor  $\frac{k_i k_j}{2m-1}$  é, na verdade, a média de arestas que haverá entre  $v_i$  e  $v_j$ , mas no limite, quando  $m$  cresce, a média e a **chance** de termos a aresta são iguais, e podemos ignorar o valor  $-1$  do denominador:

$$p_{ij} = \frac{k_i k_j}{2m}$$

# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração
- 3 Modularidade**
- 4 Detecção de comunidades
- 5 Aplicações

# Modularidade

A **modularidade** é uma forma mais precisa e matematicamente correta de avaliar a **homofilia de uma rede**, e é baseada no modelo de configuração.

# Modularidade

A **modularidade** é uma forma mais precisa e matematicamente correta de avaliar a **homofilia de uma rede**, e é baseada no modelo de configuração.

- Seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós, e  $s_i$  é o grupo do nó  $v_i$ .

# Modularidade

A **modularidade** é uma forma mais precisa e matematicamente correta de avaliar a **homofilia de uma rede**, e é baseada no modelo de configuração.

- Seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós, e  $s_i$  é o grupo do nó  $v_i$ .
- No modelo de configuração, a chance de uma aresta entre  $v_i$  e  $v_j$  existir é:  $\frac{k_i k_j}{2m}$ .

# Modularidade

A **modularidade** é uma forma mais precisa e matematicamente correta de avaliar a **homofilia de uma rede**, e é baseada no modelo de configuração.

- Seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós, e  $s_i$  é o grupo do nó  $v_i$ .
- No modelo de configuração, a chance de uma aresta entre  $v_i$  e  $v_j$  existir é:  $\frac{k_i k_j}{2m}$ .
- Qual é o **total de arestas esperadas** entre vértices que pertencem ao **mesmo grupo**?

# Modularidade

A **modularidade** é uma forma mais precisa e matematicamente correta de avaliar a **homofilia de uma rede**, e é baseada no modelo de configuração.

- Seja  $A = \{A_1, \dots, A_k\}$  uma coleção de  $k$  grupos de nós, e  $s_i$  é o grupo do nó  $v_i$ .
- No modelo de configuração, a chance de uma aresta entre  $v_i$  e  $v_j$  existir é:  $\frac{k_i k_j}{2m}$ .
- Qual é o **total de arestas esperadas** entre vértices que pertencem ao **mesmo grupo**?

$$\frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j),$$

onde  $\delta(s_i, s_j) = 1$  se  $s_i = s_j$ , e  $\delta(s_i, s_j) = 0$  se  $s_i \neq s_j$  (delta de Kronecker).

# Modularidade

- **Quantidade esperada** de arestas entre vértices no mesmo grupo:

$$\frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j).$$

# Modularidade

- **Quantidade esperada** de arestas entre vértices no mesmo grupo:

$$\frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j).$$

- **Quantidade real** de arestas entre vértices no mesmo grupo ( $a_{ij} = 1$  se há aresta):

$$\sum_{(v_i, v_j) \in E} \delta(s_i, s_j) = \frac{1}{2} \sum_{ij} a_{ij} \delta(s_i, s_j).$$

# Modularidade

**Diferença** entre o número real e esperado de arestas dentro dos grupos:

$$\frac{1}{2} \sum_{ij} a_{ij} \delta(s_i, s_j) - \frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j) = \frac{1}{2} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j).$$

# Modularidade

**Diferença** entre o número real e esperado de arestas dentro dos grupos:

$$\frac{1}{2} \sum_{ij} a_{ij} \delta(s_i, s_j) - \frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j) = \frac{1}{2} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j).$$

Geralmente, não queremos a diferença absoluta, mas a **diferença relativa**:

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j).$$

# Modularidade

**Diferença** entre o número real e esperado de arestas dentro dos grupos:

$$\frac{1}{2} \sum_{ij} a_{ij} \delta(s_i, s_j) - \frac{1}{2} \sum_{ij} \frac{k_i k_j}{2m} \delta(s_i, s_j) = \frac{1}{2} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j).$$

Geralmente, não queremos a diferença absoluta, mas a **diferença relativa**:

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j).$$

O valor  $Q$  é chamado de **modularidade**.

# Modularidade

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j)$$

A **modularidade**  $Q$  avalia, dados os grupos de nós em uma rede, o número de arestas intra-grupo existentes, calculando o número real de arestas intragrupo menos o número esperado dessas arestas em uma rede com os mesmos nós, os mesmos grupos e os mesmos graus dos nós, mas com as arestas colocadas aleatoriamente.

# Modularidade

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j)$$

A **modularidade**  $Q$  avalia, dados os grupos de nós em uma rede, o número de arestas intra-grupo existentes, calculando o número real de arestas intragrupo menos o número esperado dessas arestas em uma rede com os mesmos nós, os mesmos grupos e os mesmos graus dos nós, mas com as arestas colocadas aleatoriamente.

A **modularidade** é a forma apropriada de avaliar a **homofilia de uma rede**.

# Modularidade

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j)$$

A **modularidade**  $Q$  avalia, dados os grupos de nós em uma rede, o número de arestas intra-grupo existentes, calculando o número real de arestas intragrupo menos o número esperado dessas arestas em uma rede com os mesmos nós, os mesmos grupos e os mesmos graus dos nós, mas com as arestas colocadas aleatoriamente.

A **modularidade** é a forma apropriada de avaliar a **homofilia de uma rede**.

A **modularidade** foi proposta por [Mark Newman](#), da Universidade de Michigan, cujos trabalhos estão entre aqueles com maior impacto (em ciências exatas) no século XXI.

# Modularidade

## Resumo da fórmula:

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j), \text{ onde}$$

- $m = |E|$  é o número de arestas na rede;
- $a_{ij} = 1$  se há aresta entre  $v_i$  e  $v_j$ , senão 0;
- $k_i = d(v_i)$  é o grau do vértice  $v_i \in V$ ;
- $\delta(s_i, s_j) = 1$  se  $v_i$  e  $v_j$  estão no mesmo grupo, senão 0.

# Modularidade

## Resumo da fórmula:

$$Q = \frac{1}{2m} \sum_{ij} \left( a_{ij} - \frac{k_i k_j}{2m} \right) \delta(s_i, s_j), \text{ onde}$$

- $m = |E|$  é o número de arestas na rede;
- $a_{ij} = 1$  se há aresta entre  $v_i$  e  $v_j$ , senão  $0$ ;
- $k_i = d(v_i)$  é o grau do vértice  $v_i \in V$ ;
- $\delta(s_i, s_j) = 1$  se  $v_i$  e  $v_j$  estão no mesmo grupo, senão  $0$ .

Os valores da modularidade estão no intervalo  $[-\frac{1}{2}, 1]$ .

# Modularidade

Forma mais fácil de calcular a modularidade:

$$Q = \sum_i (e_{ii} - a_i^2).$$

# Modularidade

Forma mais fácil de calcular a modularidade:

$$Q = \sum_i (e_{ii} - a_i^2).$$

- O valor  $e_{ii}$  é a **fração de stubs** de arestas dentro do grupo  $i$ .  
( $2 \times$  o número de arestas no grupo  $i$  dividido por  $2m$ )  
 $e_{ii}$  representa a fração real de arestas dentro dos grupos.

# Modularidade

Forma mais fácil de calcular a modularidade:

$$Q = \sum_i (e_{ii} - a_i^2).$$

- O valor  $e_{ii}$  é a **fração de stubs** de arestas dentro do grupo  $i$ .  
( $2 \times$  o número de arestas no grupo  $i$  dividido por  $2m$ )  
 $e_{ii}$  representa a fração real de arestas dentro dos grupos.
- O valor  $a_i$  é a **fração de stubs** de arestas incidentes a vértices no grupo  $i$ .  
(inclui as anteriores, e as arestas que vão para outros grupos)  
 $a_i^2$  representa a chance esperada de uma aresta ficar dentro dos grupos no modelo de configuração.

# Modularidade

**Observe**, se temos dois grupos:


$$Q = \sum_i (e_{ii} - a_i^2) = (e_{11} - a_1^2) + (e_{22} - a_2^2).$$

Cada um desses termos representa a **contribuição de um grupo** à modularidade da rede toda!

# Modularidade

## Voltando ao exemplo anterior:

- Qual é a **fração de arestas** real e esperada no grupo azul **no modelo de configuração**?




# Modularidade

## Voltando ao exemplo anterior:

- Qual é a **fração de arestas** real e esperada no grupo azul **no modelo de configuração**?

**Exercício.**




# Modularidade

## Voltando ao exemplo anterior:

- Qual é a **fração de arestas** real e esperada no grupo azul **no modelo de configuração**?

### Exercício.

- Qual é o **número de arestas** real e esperado no grupo azul **no modelo de configuração**?



# Modularidade


## Voltando ao exemplo anterior:

- Qual é a **fração de arestas** real e esperada no grupo azul **no modelo de configuração**?

**Exercício.**

- Qual é o **número de arestas** real e esperado no grupo azul **no modelo de configuração**?

**Exercício.**



# Modularidade

## Voltando ao exemplo anterior:

- Qual é a **fração de arestas** real e esperada no grupo azul **no modelo de configuração**?


**Exercício.**

- Qual é o **número de arestas** real e esperado no grupo azul **no modelo de configuração**?

**Exercício.**

**Dica:** calcular os valores  $e_{ij}$ ,  $a_i^2$  usando a fórmula do slide anterior.

**Compare** os valores com os obtidos no modelo que não considera os graus.



# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração
- 3 Modularidade
- 4 Detecção de comunidades**
- 5 Aplicações


# Detecção de comunidades

## O que é detecção de comunidades?

- Suponha agora que temos **apenas** o grafo  $G = (V, E)$ .
- Existem muitas formas de **dividir os vértices** em grupos:  $2^{|V|}$  divisões diferentes!
- Algumas divisões (partições) são **melhores** do que outras.

# Detecção de comunidades: clube de karatê do Zachary

Algumas divisões (partições) são **melhores** do que outras.



# Detecção de comunidades

## **Ideia de todos os métodos de detecção de comunidades:**

*Devemos ter muitas arestas entre vértices do mesmo grupo, e comparativamente poucas arestas entre vértices de grupos diferentes.*

# Detecção de comunidades

## Ideia de todos os métodos de detecção de comunidades:

*Devemos ter muitas arestas entre vértices do mesmo grupo, e comparativamente poucas arestas entre vértices de grupos diferentes.*

## Ideias e abordagens para a detecção de comunidades:

- Um bom grupo seria aquele no qual a **densidade** das arestas no grupo é maior.

# Detecção de comunidades

## Ideia de todos os métodos de detecção de comunidades:

*Devemos ter muitas arestas entre vértices do mesmo grupo, e comparativamente poucas arestas entre vértices de grupos diferentes.*

## Ideias e abordagens para a detecção de comunidades:

- Um bom grupo seria aquele no qual a **densidade** das arestas no grupo é maior.
- *Hierarchical clustering*: os **grupos** podem **conter outros grupos**.

# Detecção de comunidades

## Ideia de todos os métodos de detecção de comunidades:

*Devemos ter muitas arestas entre vértices do mesmo grupo, e comparativamente poucas arestas entre vértices de grupos diferentes.*

## Ideias e abordagens para a detecção de comunidades:

- Um bom grupo seria aquele no qual a **densidade** das arestas no grupo é maior.
- *Hierarchical clustering*: os **grupos** podem **conter outros grupos**.
- Métodos baseados na **modularidade**: a melhor partição é aquela para a qual a função  $Q$  da modularidade possui o maior valor!

Santo Fortunato: “Community detection in graphs” (2010).  
→ 8264 citações no Scopus, 12681 citações no Google Scholar.

# Detecção de comunidades

Encontrar uma partição dos vértices em grupos que maximize o valor de modularidade é um problema **NP-difícil!**

U. Brandes et al., “On Modularity Clustering”, *IEEE Transactions on Knowledge and Data Engineering*, v. 20, pp. 172-188 (2008).

# Detecção de comunidades

Encontrar uma partição dos vértices em grupos que maximize o valor de modularidade é um problema **NP-difícil!**

U. Brandes et al., “On Modularity Clustering”, *IEEE Transactions on Knowledge and Data Engineering*, v. 20, pp. 172-188 (2008).

Mesmo assim, a modularidade é muito importante para os métodos de **detecção de comunidades**, sendo considerada como um *gold standard* para boas comunidades.

- Ela permite **avaliar** se uma dada divisão dos vértices em grupos é **apropriada**.
- Enquanto **maior** o valor da modularidade  $Q$ , **melhor** é a partição proposta.

**A modularidade é a função objetivo a ser maximizada no problema de encontrar a melhor divisão dos vértices em grupos!**

# Detecção de comunidades

**Exemplo de aplicação:** método de agrupamento hierárquico **guloso**.

- 1 Não sabemos quantos grupos temos. Então, iniciamos com **todos os vértices em grupos diferentes**;
- 2 Em cada passo, escolhemos e adicionamos ao grafo **uma aresta** que junte dois grupos de forma que a **modularidade aumente** no maior valor possível;
- 3 Finalizamos o algoritmo com um único grupo, e **escolhemos a melhor** das  $n - 1$  divisões encontradas durante a execução.

**Complexidade** em grafos esparsos:  $O(n^2)$ .

**Melhorado** usando estruturas de dados eficientes, passa a  $O(n \log^2(n))$ .

→ “Fast algorithm for detecting community structure in networks”

# Detecção de comunidades em redes dinâmicas

**Comunidades dinâmicas:** o que significa identificar comunidades em redes dinâmicas (onde cada aresta ou vértice possui um momento de tempo associado)?

# Detecção de comunidades em redes dinâmicas

**Comunidades dinâmicas:** o que significa identificar comunidades em redes dinâmicas (onde cada aresta ou vértice possui um momento de tempo associado)?

Algoritmos precisam identificar as **etapas do ciclo de vida** das comunidades:

- Nascimento,
- Expansão ou contração,
- Fusão com outra comunidade,
- Divisão em duas ou mais comunidades,
- Morte.

**É um problema mais complexo e uma ativa área de pesquisa!**

# Resumo

- 1 Revisão do conteúdo
- 2 Modelo de configuração
- 3 Modularidade
- 4 Detecção de comunidades
- 5 Aplicações**

# Aplicações

A **modularidade** é usada no contexto da detecção de comunidades nas **mais diversas áreas** para identificar estruturas ou grupos de vértices presentes nessas redes:

- Nas redes de interação de proteínas, as comunidades agrupam **proteínas que têm a mesma função específica** dentro da célula;
- Na World Wide Web, os grupos correspondem a **páginas relacionadas aos mesmos tópicos**, interesses ou negócios;
- Identificar grupos de **clientes com interesses semelhantes** nas redes de clientes e produtos permite criar bons sistemas de recomendação ([www.amazon.com](http://www.amazon.com)).

## Material bibliográfico

M. Newman, M. Girvan: “Finding and evaluating community structure in networks” (2004).

S. Fortunato: “Community detection in graphs” (2010).

S. Fortunato, D. Hric: “Community detection in networks: A user guide” (2016).

# Dúvidas

Dúvidas?