

DATA MINING & MACHINE LEARNING (I)

Thiago Marzagão



Centro Universitário

análise de grafos



análise de grafos

- ▶ Exemplos de grafos:

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)
- ▶ ... licitações (empresa A é co-licitante da empresa B, etc)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)
- ▶ ... licitações (empresa A é co-licitante da empresa B, etc)
- ▶ ... sociedades (fulano é sócio de beltrano, etc)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)
- ▶ ... licitações (empresa A é co-licitante da empresa B, etc)
- ▶ ... sociedades (fulano é sócio de beltrano, etc)
- ▶ ... filmes (ator A contracenou com ator B, etc)

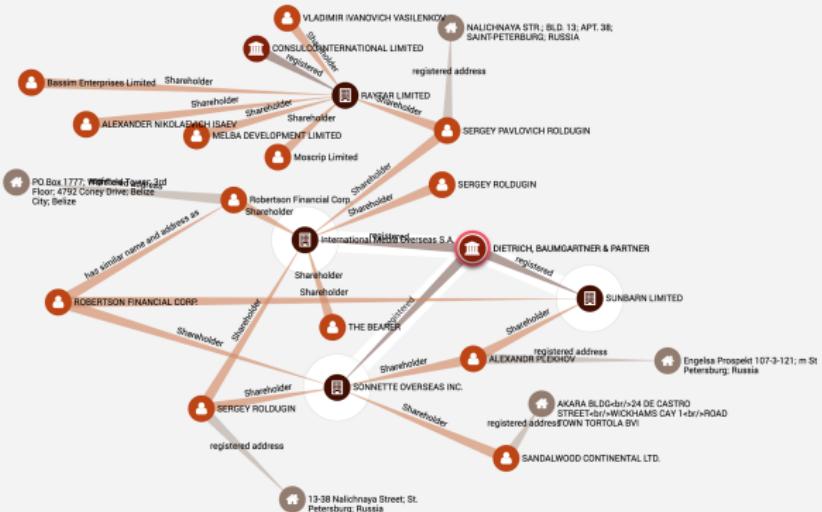
análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)
- ▶ ... licitações (empresa A é co-licitante da empresa B, etc)
- ▶ ... sociedades (fulano é sócio de beltrano, etc)
- ▶ ... filmes (ator A contracenou com ator B, etc)
- ▶ ... relacionamentos diversos (cf. Bearman, Moody e Stovel 2004)

análise de grafos

- ▶ Exemplos de grafos:
- ▶ ... redes sociais (fulano é amigo de beltrano, etc)
- ▶ ... crime organizado (fulano envia dinheiro p/ beltrano, etc)
- ▶ ... processos judiciais (processo A menciona processo B, etc)
- ▶ ... licitações (empresa A é co-licitante da empresa B, etc)
- ▶ ... sociedades (fulano é sócio de beltrano, etc)
- ▶ ... filmes (ator A contracenou com ator B, etc)
- ▶ ... relacionamentos diversos (cf. Bearman, Moody e Stovel 2004)
- ▶ ... Panamá Papers

Panamá Papers



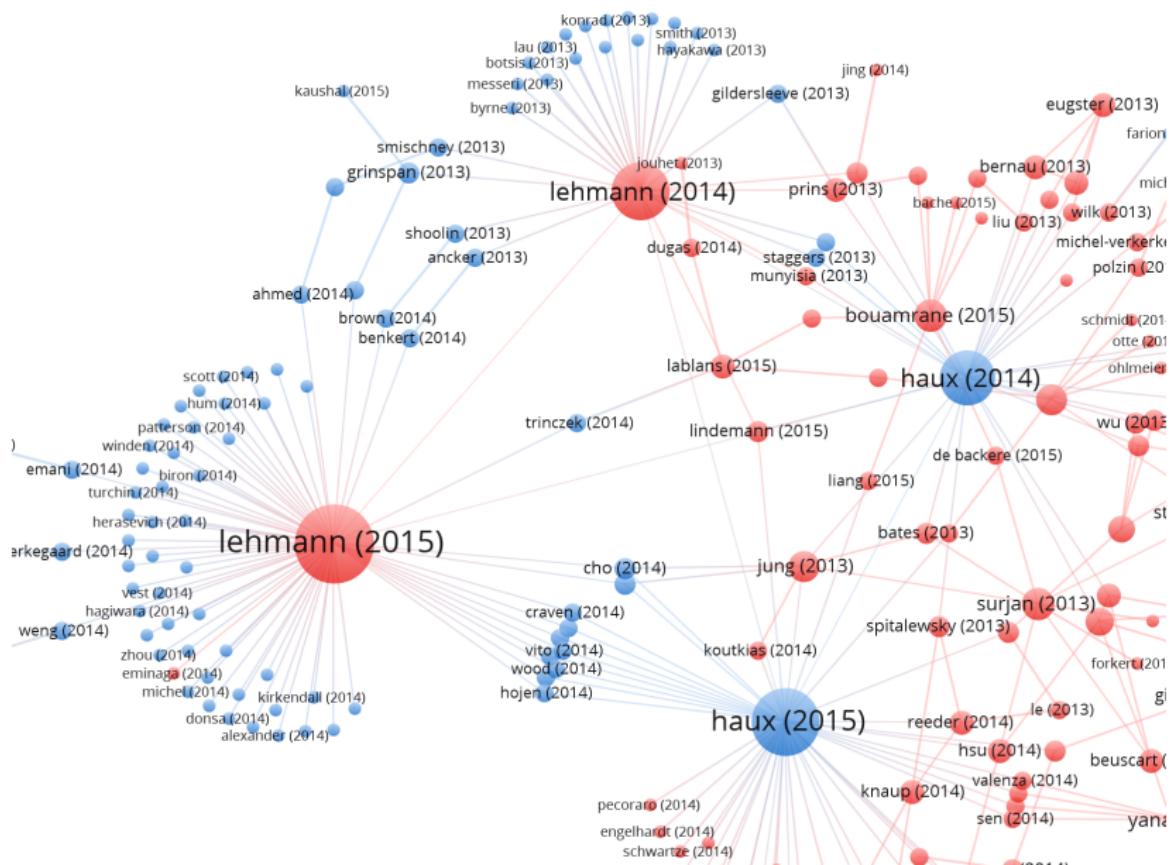
Category
Company
Officer
Address
Client

Category
Officer
Address
Company
Registered
Client

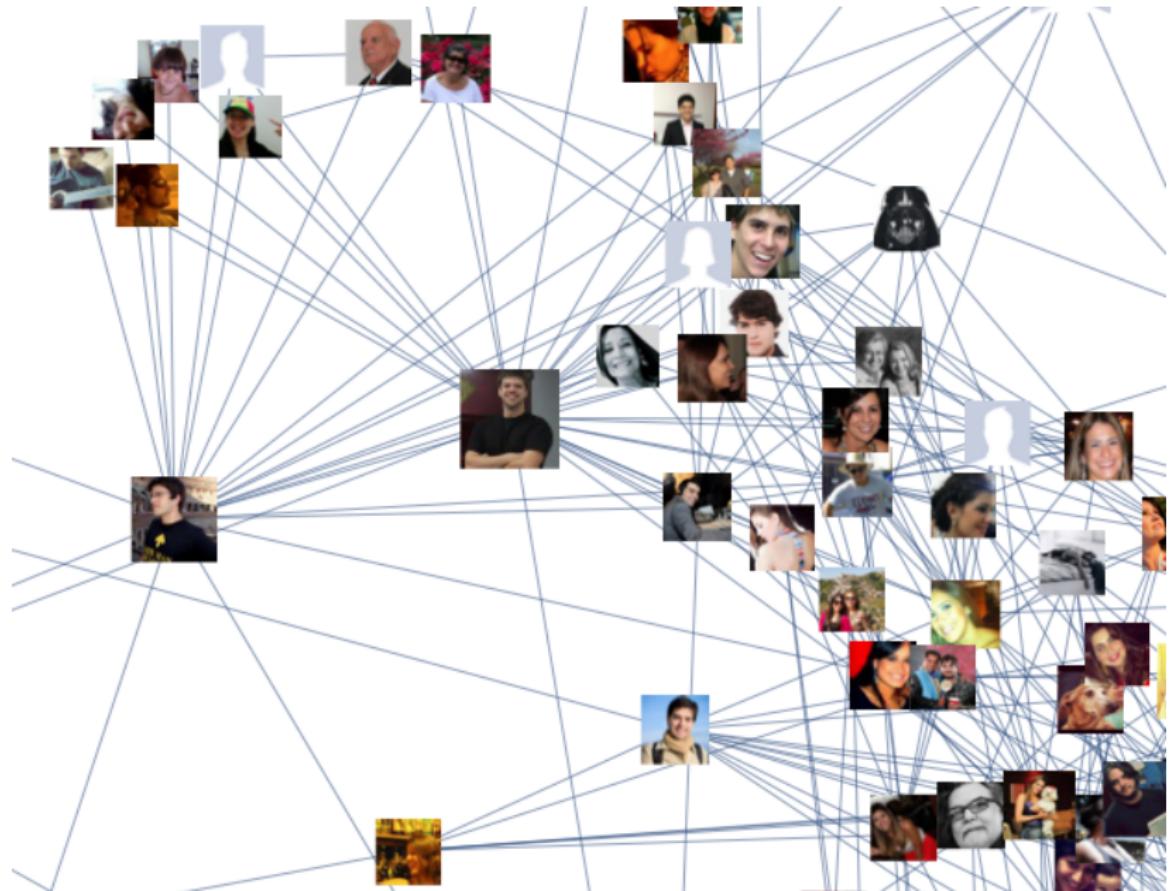
Type
Is officer of
Registered addr.
Registered
Has similar nam...



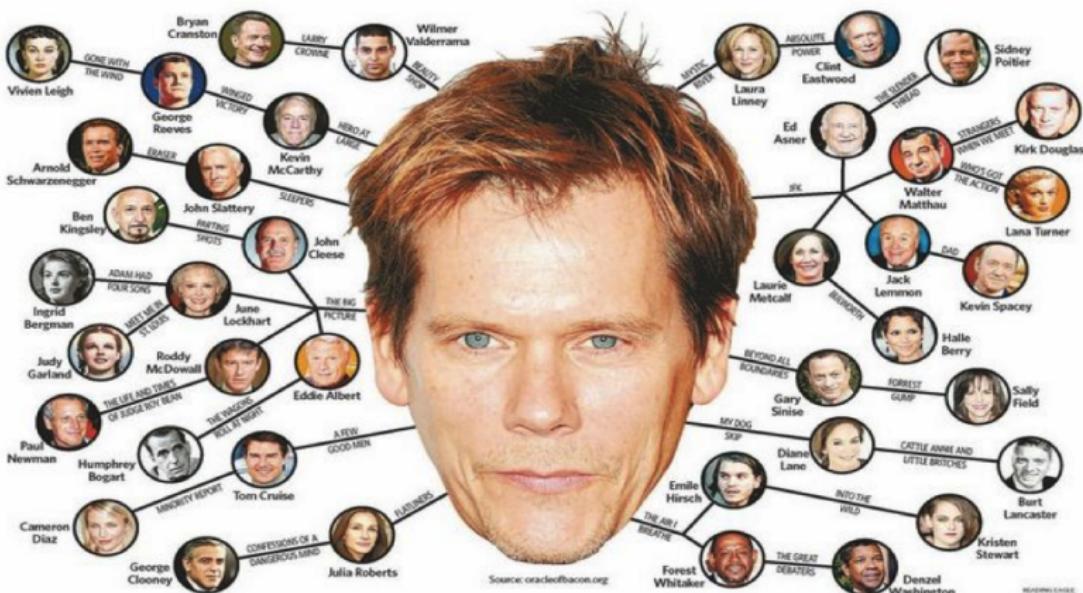
citações acadêmicas



redes sociais



six degrees of Kevin Bacon



nós e arestas

- ▶ Nós. São os “pontos” da rede. Pessoas, empresas, artigos acadêmicos, etc.

nós e arestas

- ▶ Nós. São os “pontos” da rede. Pessoas, empresas, artigos acadêmicos, etc.
- ▶ (Às vezes são chamados de vértices.)

nós e arestas

- ▶ Nós. São os “pontos” da rede. Pessoas, empresas, artigos acadêmicos, etc.
- ▶ (Às vezes são chamados de vértices.)
- ▶ Arestas. São as “ligações” entre os nós.

nós e arestas

- ▶ Nós. São os “pontos” da rede. Pessoas, empresas, artigos acadêmicos, etc.
- ▶ (Às vezes são chamados de vértices.)
- ▶ Arestas. São as “ligações” entre os nós.
- ▶ Arestas podem ser direcionadas (ex.: Twitter) ou não-direcionadas (ex.: Facebook).

nós e arestas

- ▶ Cada nó tem um grau.

nós e arestas

- ▶ Cada nó tem um grau.
- ▶ Grau = qtde. de arestas do nó.

nós e arestas

- ▶ Cada nó tem um grau.
- ▶ Grau = qtde. de arestas do nó.
- ▶ (Às vezes chamado de valência.)

nós e arestas

- ▶ Cada nó tem um grau.
- ▶ Grau = qtde. de arestas do nó.
- ▶ (Às vezes chamado de valência.)
- ▶ Se o grafo é direcionado cada nó tem dois graus: o de saída e o de entrada.

caminhos

- ▶ Caminho mínimo: é o caminho mais curto entre dois nós.

como identificar os nós mais importantes?

- ▶ Métricas de centralidade:

como identificar os nós mais importantes?

- ▶ Métricas de centralidade:
- ▶ centralidade de grau: é simplesmente o grau do nó

como identificar os nós mais importantes?

- ▶ Métricas de centralidade:
- ▶ centralidade de grau: é simplesmente o grau do nó
- ▶ centralidade de proximidade: $1 / (\text{soma dos caminhos mínimos até todos os outros nós})$

como identificar os nós mais importantes?

- ▶ Métricas de centralidade:
- ▶ centralidade de grau: é simplesmente o grau do nó
- ▶ centralidade de proximidade: $1 / (\text{soma dos caminhos mínimos até todos os outros nós})$
- ▶ centralidade de intermediação: qtde. de caminhos mínimos que passam pelo nó (às vezes dividida pelo total de caminhos mínimos existentes no grafo)

como identificar os nós mais importantes?

- ▶ Métricas de centralidade:
- ▶ centralidade de grau: é simplesmente o grau do nó
- ▶ centralidade de proximidade: $1 / (\text{soma dos caminhos mínimos até todos os outros nós})$
- ▶ centralidade de intermediação: qtde. de caminhos mínimos que passam pelo nó (às vezes dividida pelo total de caminhos mínimos existentes no grafo)
- ▶ ... diversas outras (exemplo: PageRank, que se baseia na centralidade dos nós adjacentes)

coeficiente de clusterização

- ▶ Atenção! Aqui usamos o termo “clusterização num sentido totalmente distinto daquele que vimos nas aulas 2-3.

coeficiente de clusterização

- ▶ Atenção! Aqui usamos o termo “clusterização” num sentido totalmente distinto daquele que vimos nas aulas 2-3.
- ▶ Os nós adjacentes ao nó x formam uma “comunidade”?

coeficiente de clusterização

- ▶ Atenção! Aqui usamos o termo “clusterização” num sentido totalmente distinto daquele que vimos nas aulas 2-3.
- ▶ Os nós adjacentes ao nó x formam uma “comunidade”?
- ▶ Coeficiente de clusterização: qtde. de arestas entre os vizinhos imediatos de x / qtde. de arestas que *poderiam existir* entre os vizinhos imediatos de x .

coeficiente de clusterização

- ▶ Atenção! Aqui usamos o termo “clusterização num sentido totalmente distinto daquele que vimos nas aulas 2-3.
- ▶ Os nós adjacentes ao nó x formam uma “comunidade”?
- ▶ Coeficiente de clusterização: qtde. de arestas entre os vizinhos imediatos de x / qtde. de arestas que *poderiam existir* entre os vizinhos imediatos de x .
- ▶ Em outras palavras: o quanto “conectados” entre si são os vizinhos de x ?

atributos do grafo

- ▶ Qtde. de nós.

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?
- ▶ Diâmetro: maior caminho mínimo.

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?
- ▶ Diâmetro: maior caminho mínimo.
- ▶ Grau médio

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?
- ▶ Diâmetro: maior caminho mínimo.
- ▶ Grau médio
 - ▶ grafo não-direcionado: $(2L)/N$

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?
- ▶ Diâmetro: maior caminho mínimo.
- ▶ Grau médio
 - ▶ grafo não-direcionado: $(2L)/N$
 - ▶ grafo direcionado: L/N

atributos do grafo

- ▶ Qtde. de nós.
- ▶ Qtde. de arestas.
- ▶ Qtde. de arestas / qtde. de arestas que *poderiam existir*:
$$\frac{N(N - 1)}{2}$$
- ▶ Direcionado ou não-direcionado?
- ▶ Diâmetro: maior caminho mínimo.
- ▶ Grau médio
 - ▶ grafo não-direcionado: $(2L)/N$
 - ▶ grafo direcionado: L/N
- ▶ Coeficiente de clusterização médio.

o que não vamos ver

- ▶ Grafos aleatórios.

o que não vamos ver

- ▶ Grafos aleatórios.
- ▶ Algoritmos de caminho mínimo.

o que não vamos ver

- ▶ Grafos aleatórios.
- ▶ Algoritmos de caminho mínimo.
- ▶ ... muito mais!

exercício - Panamá Papers

