

# **MINERAÇÃO DE DADOS EM REDES COMPLEXAS**

**Prof. Ronaldo R. Goldschmidt**

**Instituto Militar de Engenharia**

**Seção de Engenharia de Computação (SE/8)**

**[ronaldo.rgold@ime.eb.br](mailto:ronaldo.rgold@ime.eb.br) / [ronaldo.rgold@gmail.com](mailto:ronaldo.rgold@gmail.com)**

# **ROTEIRO**

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**

# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**

# POSICIONAMENTO E MOTIVAÇÃO

- Coleta de dados em vários formatos, por meio de diversos recursos/aplicações em várias áreas:
  - Internet, dispositivos móveis, sensores, sistemas de automação, sistemas de informação, ...
  - Redes sociais, AVAs, redes de telecomunicações, operações com cartões de crédito, ...
  - Governo, (Bio)Ciências, Finanças, Seguros, Segurança, ...
  - IoT (Internet of Things – Internet das Coisas)
- Quanta informação é criada a cada ano?



# POSICIONAMENTO E MOTIVAÇÃO

- Segundo a revista Science (2011): o mundo foi capaz de armazenar **295 exabytes** de informação no ano de **2007**.
  - 1 exabyte = 1012 megabytes
  - Cerca de 800 megabytes para cada ser humano.
  - Equivalente ao conteúdo textual de mais de 300 livros.
- **Atualmente** a NASA possui dados na ordem de **bilhões de gigabytes**.
- Estima-se que em **2020**, a humanidade disporá de **44 zettabytes** de dados.
  - 1 zettabyte = 44 trilhões de gigabytes ( $44 \times 2^{70}$  bytes)
  - Taxa de crescimento de dados mundial em torno de 40% ao ano na próxima década.

Fontes:


[www.sciencemag.org/content/early/2011/02/09/science.1200970.full.pdf](http://www.sciencemag.org/content/early/2011/02/09/science.1200970.full.pdf)

<http://www.nasa.gov/open/plan/data-gov.html>

[www.emc.com/leadership/digital-universe/index.htm](http://www.emc.com/leadership/digital-universe/index.htm)

# POSICIONAMENTO E MOTIVAÇÃO

- Nossa situação atual é a de **sobrecarga de informação...**



# POSICIONAMENTO E MOTIVAÇÃO

**Grandes Desafios da Pesquisa em Computação no Brasil (SBC, 2014)**

**Gestão da Informação em Grandes Volumes de Dados Multimídia Distribuídos**

**Ciência de Dados**

Astronomia  
Biologia  
Defesa  
Educação  
Energia  
Engenharia  
Esporte  
Física  
Saúde  
Etc...



Computação:

- Gerência de Dados
- **Análise de Dados**



Temas Relacionados:

- Workflows Científicos
- Procedência de Dados
- Web Semântica
- **Mineração de Dados**
- Etc...



# POSICIONAMENTO E MOTIVAÇÃO

## Tema de Interesse: Análise de Redes Complexas



**Grande número de elementos fortemente interconectados**

**Compreensão da dinâmica evolutiva dessas redes**

**Mineração de Grafos**

**Heterogeneidade de elementos e de ligações**



# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

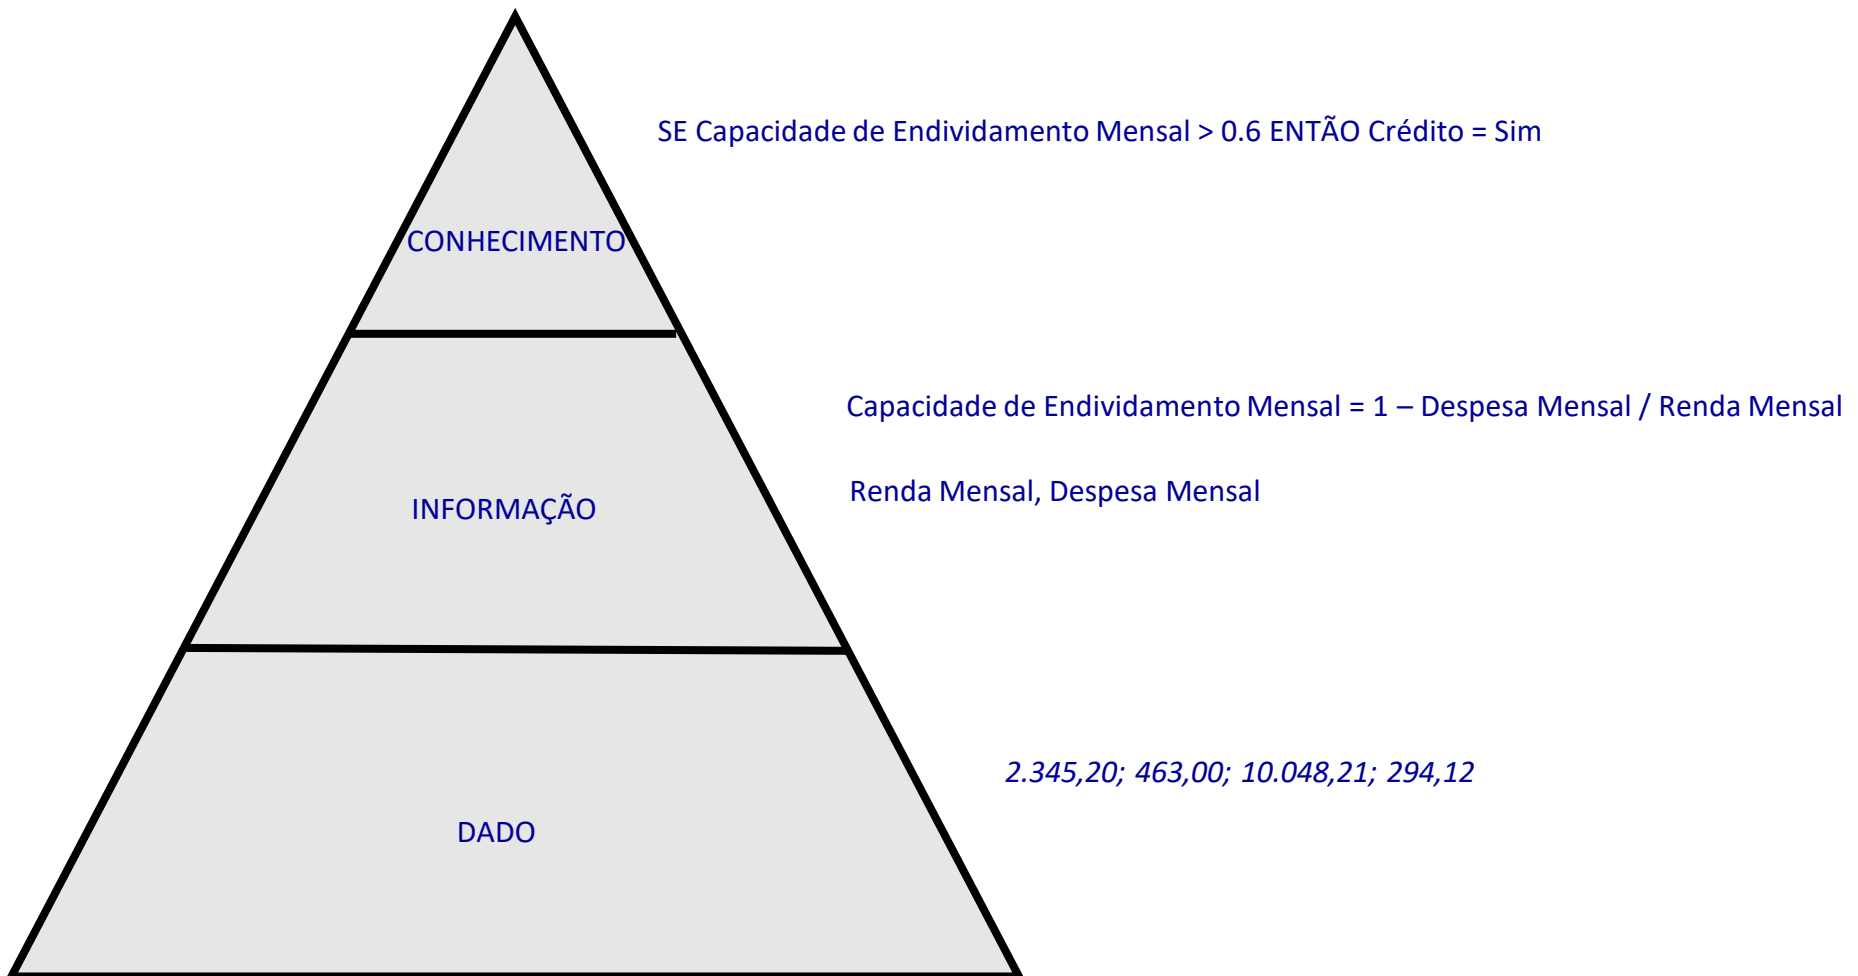
**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**

# CONCEITOS BÁSICOS – ANÁLISE DE DADOS

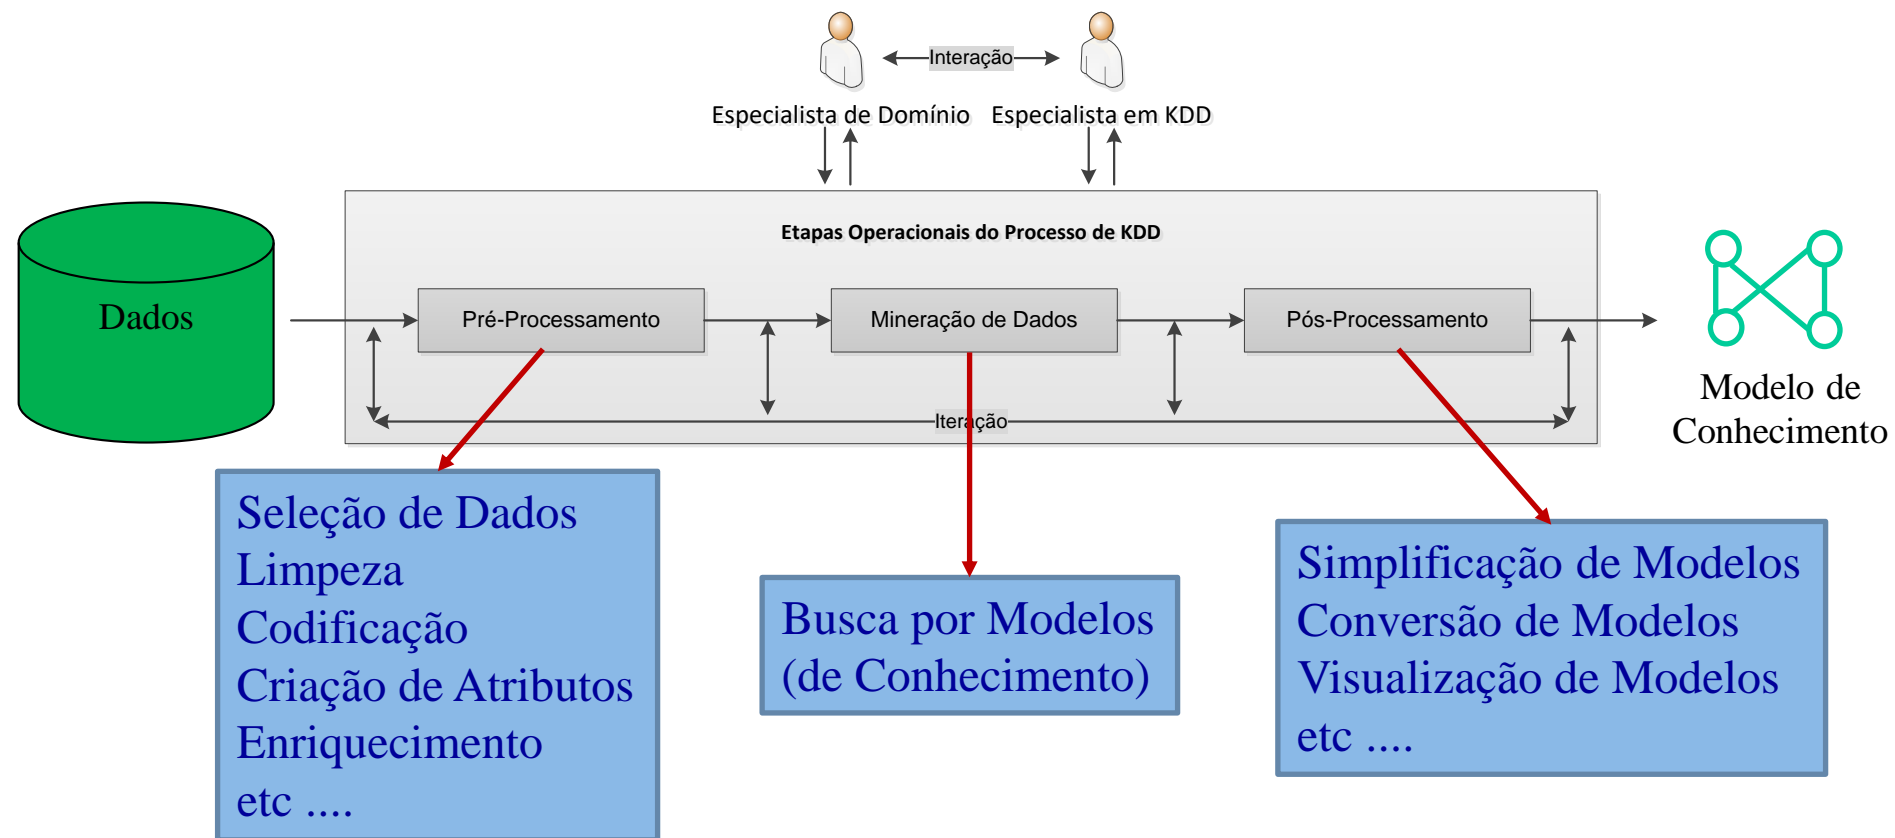
## Hierarquia Dado - Informação - Conhecimento:



# CONCEITOS BÁSICOS – ANÁLISE DE DADOS

## Descoberta de Conhecimento / Análise de Dados


### KDD: Knowledge Discovery in Databases



# CONCEITOS BÁSICOS – ANÁLISE DE DADOS

Exemplo de aplicação na área de concessão de crédito:


Conjunto de dados (Fatos)



# CONCEITOS BÁSICOS – ANÁLISE DE DADOS

Exemplo de aplicação na área de concessão de crédito:

Padrão: Se renda > R\$ t Então Crédito = SIM (Cto)



# CONCEITOS BÁSICOS – ANÁLISE DE DADOS

## Multidisciplinaridade




# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafo – Definição

$G(V, E)$ : Estrutura matemática

- $V$ : conjunto de nós ou vértices
- $E$ : conjunto de arestas, que conectam os nós



Exemplos sobre conceitos importantes:

- Vizinhos de C:  $\{B, D\}$
- Caminhos entre A e D:  
     $A - B - D$   
     $A - B - C - D$
- Comprimento de caminho: 2 e 3
- Distância entre A e D: 2




# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafo Dirigido – Definição

$G(V, E)$ : Considera a direção dos relacionamentos

- $V$ : conjunto de nós ou vértices
- $E$ : conjunto de arestas, que conectam os nós




Exemplo de aplicação: Twitter

# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafos – Representação Computacional

- Matriz de adjacência  $M_{n \times n}$  onde:
  - $M_{i,j} = 1$  se existe uma aresta entre os nós  $i$  e  $j$
  - $M_{i,j} = 0$  se não existe uma aresta entre os nós  $i$  e  $j$





$M_{i,j}$	1	2	3	4
1	0	1	0	0
2	1	0	1	1
3	0	1	0	1
4	0	1	1	0

# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafos – Representação Computacional


- Lista de adjacência: representação de vértices e seus vértices adjacentes



# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafos – Exemplos de Métricas Topológicas

- Número de vizinhos comuns –  $cn(i,j)$



$$cn(1,2) = 1$$

$$cn(1,3) = 2$$

$$cn(1,4) = 1$$

$$cn(2,3) = 1$$

$$cn(2,4) = 2$$

$$cn(4,5) = 1$$

$$cn(4,8) = 2$$


$$cn(7,9) = 0$$

# CONCEITOS BÁSICOS – TEORIA DE GRAFOS

## Grafos – Exemplos de Métricas Topológicas

- Coeficiente de Jaccard –  $JC(i,j)$ : Relação entre o número de vizinhos comuns e o total de vizinhos

$$JC(i,j) = \frac{|Viz(i) \cap Viz(j)|}{|Viz(i) \cup Viz(j)|}$$



$$JC(1,2) = 1/5$$

$$JC(1,3) = 1/5$$

$$JC(1,4) = 2/3$$

$$JC(1,5) = 0$$

$$JC(2,3) = 2/4$$

$$JC(2,4) = 1/4$$

$$JC(2,5) = 1/3$$

$$JC(3,4) = 1/4$$

$$JC(3,5) = 1/3$$

$$JC(4,5) = 0$$

# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**


**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**

# TAREFAS DE MINERAÇÃO CLÁSSICAS


## CLASSIFICAÇÃO – EXEMPLO DE APLICAÇÃO





# TAREFAS DE MINERAÇÃO CLÁSSICAS

## CLASSIFICAÇÃO – PROBLEMA



# TAREFAS DE MINERAÇÃO CLÁSSICAS

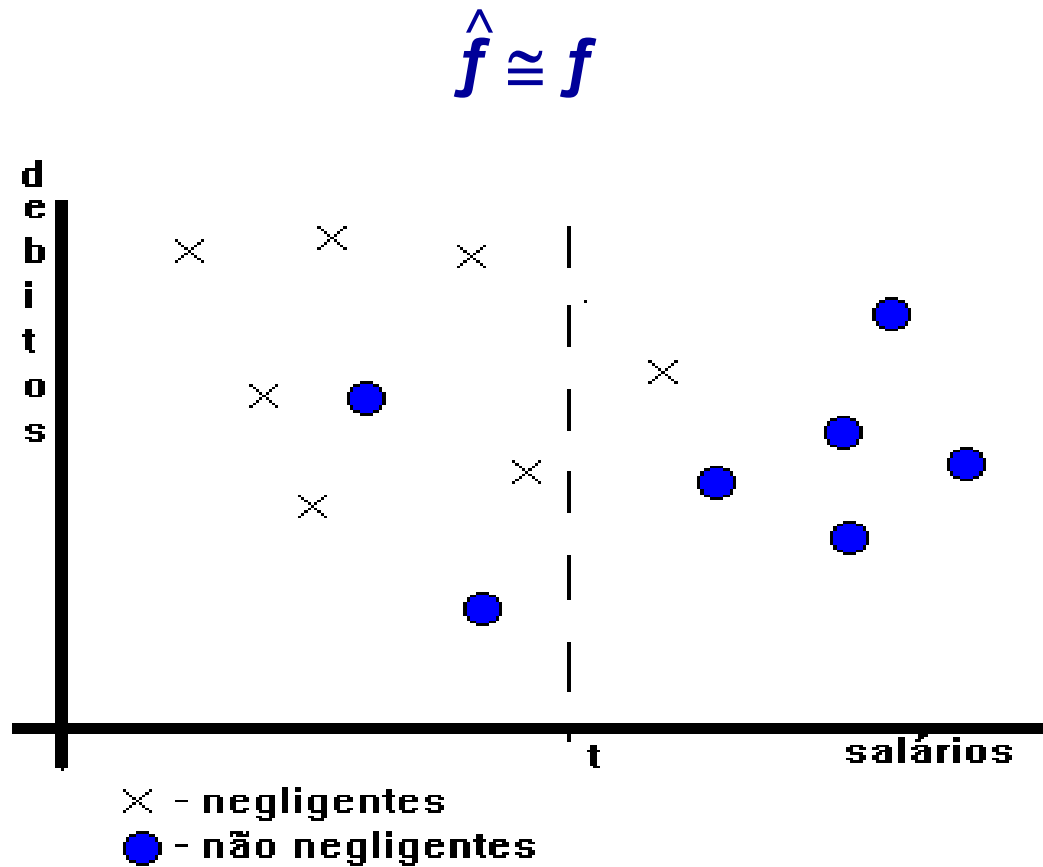
## CLASSIFICAÇÃO – OBJETIVO

$$\hat{f} \cong f$$



# TAREFAS DE MINERAÇÃO CLÁSSICAS


## CLASSIFICAÇÃO – EXEMPLO DE HIPÓTESE (MODELO)



# TAREFAS DE MINERAÇÃO CLÁSSICAS

## CLUSTERIZAÇÃO (AGRUPAMENTO) – CONCEITO

- Separação dos registros em n “clusters”
- Maximizar/Minimizar similaridade intra/inter cluster



# TAREFAS DE MINERAÇÃO CLÁSSICAS

## DESCOBERTA DE REGRAS DE ASSOCIAÇÃO – CONCEITO

- Regra de Associação:
  - $X \rightarrow Y$ , X e Y conjuntos de itens tal que:  $X \cap Y = \emptyset$
  - Regra frequente:  $\text{sup}(R_i) = |X \text{ e } Y| / |D| \geq \text{MinSup}$
  - Regra válida:  $\text{conf}(R_i) = |X \text{ e } Y| / |X| \geq \text{MinConf}$
- Exemplos de Regras de Associação:

- Café  $\rightarrow$  Pão
- Café  $\wedge$  Pão  $\rightarrow$  Leite

Trans	Leite	Café	Cerveja	Pão	Manteiga	Arroz	Feijão
1	Não	Sim	Não	Sim	Sim	Não	Não
2	Sim	Não	Sim	Sim	Sim	Não	Não
3	Não	Sim	Não	Sim	Sim	Não	Não
4	Sim	Sim	Não	Sim	Sim	Não	Não
5	Não	Não	Sim	Não	Não	Não	Não
6	Não	Não	Não	Não	Sim	Não	Não
7	Não	Não	Não	Sim	Não	Não	Não
8	Não	Não	Não	Não	Não	Não	Sim
9	Não	Não	Não	Não	Não	Sim	Sim
10	Não	Não	Não	Não	Não	Sim	Não

# TAREFAS DE MINERAÇÃO CLÁSSICAS

## EXEMPLOS DE FERRAMENTAS/RECURSOS

- SAS – Enterprise Miner
- SPSS
- PolyAnalist
- Intelligent Miner
- Rapid Miner
- Weka
- Tanagra
- Scikit-Learn
- WizSoft (WizRule)
- ...

# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**



# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## PREDIÇÃO DE LIGAÇÕES – CONCEITO

Construir modelos que prevejam a possibilidade de surgir uma associação entre dois vértices não interligados (Wang, 2015).

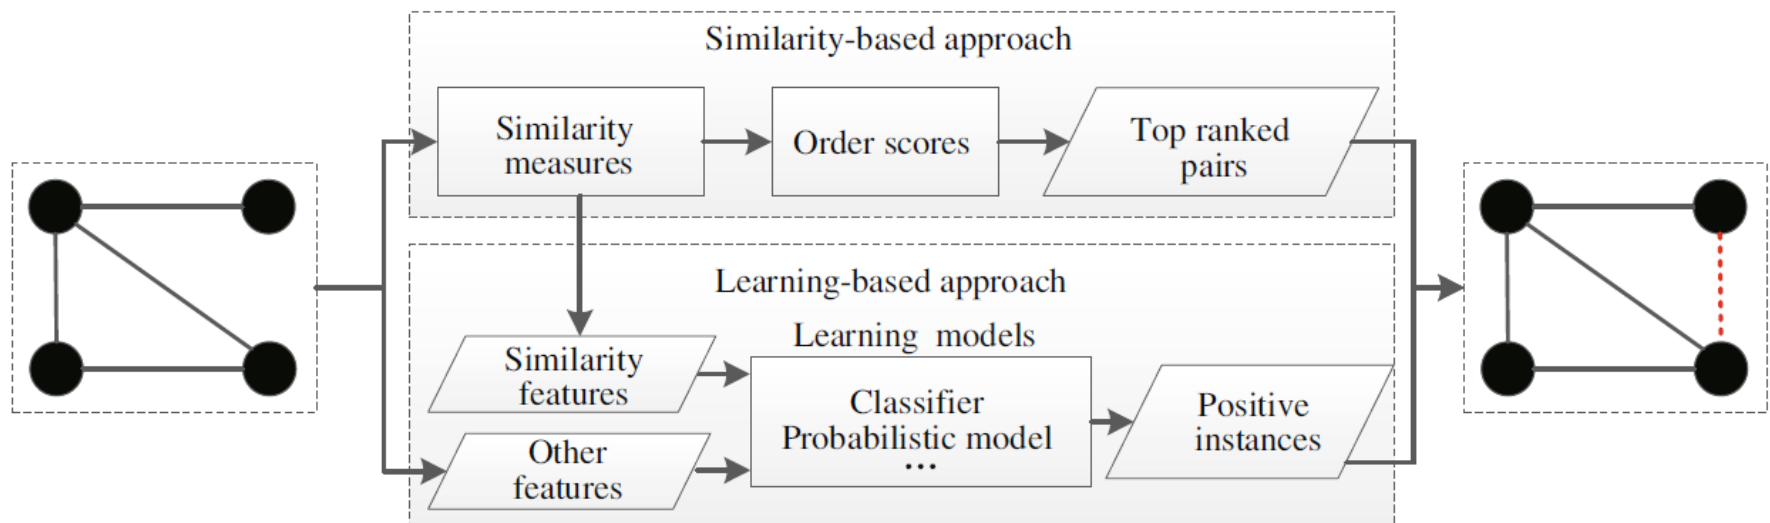
Exemplo de aplicação em redes sociais:



# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS


## PREDIÇÃO DE LIGAÇÕES – ABORDAGENS

- Não Supervisionada (Ordenação por Similaridade)
- Supervisionada (Aprendizado de Máquina)



# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## PREDIÇÃO DE LIGAÇÕES – NÃO SUPERVISIONADA



Pares  
não conectados

Pares não conectados			ORDENAÇÃO		
Nó1	Nó2	cn(i,j)	Nó1	Nó2	cn(i,j)
1	4	2	1	4	2
2	5	1	2	5	1
3	5	1	3	5	1
4	5	0	4	5	0


NOVOS

Top 2

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## PREDIÇÃO DE LIGAÇÕES – SUPERVISIONADA

Transformação do problema original em um problema de classificação binária.




<u>Nó1</u>	<u>Nó2</u>	<u>Ligação</u>
1	2	<u>sim</u>
1	3	<u>sim</u>
1	4	não
1	5	<u>sim</u>
2	3	<u>sim</u>
2	4	<u>sim</u>
2	5	não
3	4	<u>sim</u>
3	5	não
4	5	não

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## PREDIÇÃO DE LIGAÇÕES – SUPERVISIONADA

Enriquecimento do conjunto de dados com informações extraídas da rede.




Nó1	Nó2	cn(i,j)	JC(i,j)	Ligação
1	2	1	1/3	<u>sim</u>
1	3	1	1/3	<u>sim</u>
1	4	2	2/3	não
1	5	0	0	<u>sim</u>
2	3	2	2/3	<u>sim</u>
2	4	1	1/2	<u>sim</u>
2	5	1	1/3	não
3	4	1	1/2	<u>sim</u>
3	5	1	1/3	não
4	5	0	0	não

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## PREDIÇÃO DE LIGAÇÕES – SUPERVISIONADA

Aplicação de um algoritmo de classificação para aprender o modelo e identificar ligações futuras.



$$\widehat{\text{Lig}}(1, 4, \text{cn}(1,4), \text{JC}(1,4)) = \text{sim}$$



$$\widehat{\text{Lig}}(2, 5, \text{cn}(2,5), \text{JC}(2,5)) = \text{não}$$

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – CONCEITO

Identificar grupos de vértices que maximizem o número de arestas dentro do grupo e minimizem o número de arestas entre grupos distintos (Tang e Liu, 2010).

Exemplos de aplicação:

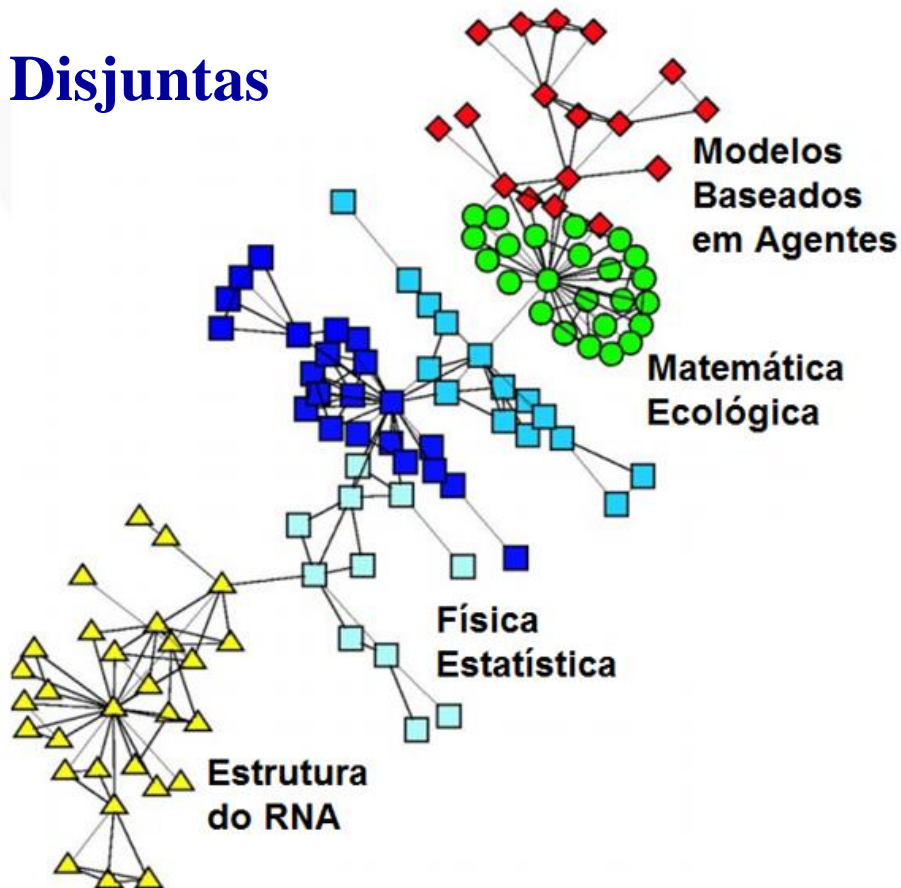





# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – TIPOS DE COMUNIDADE

### Disjuntas



### Sobrepostas



# **TAREFAS DE MINERAÇÃO – REDES COMPLEXAS**


## **DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS**

- Centrada em Vértice
- Centrada em Grupo
- Centrada em Rede
- Centrada em Hierarquia

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS

- Centrada em Vértice
  - Nós de cada grupo com propriedades semelhantes
    - Exemplo: Formação de cliques
    - Alto custo computacional




Exemplo: 4-clique e 3-clique

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS


- Centrada em Grupo
  - Considera as conexões dentro de cada grupo isoladamente, mesmo que alguns vértices do grupo tenham baixa conectividade com os demais.
    - Exemplo: grupos baseados em densidade
    - Subgrafo  $G_s(V_s, E_s)$  é  $\gamma$ -denso (quasi-clique), se  $\frac{|E_s|}{|V_s| \cdot (|V_s| - 1) / 2} \geq \gamma$

1-denso



$$|E|=6 \quad |V|=4 \rightarrow \frac{6}{4 \cdot 3 / 2} = 1 \quad (\text{clique})$$

0,83-denso



$$|E|=5 \quad |V|=4 \rightarrow \frac{5}{4 \cdot 3 / 2} = 0,83$$

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS


## DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS

- Centrada em Grupo

- Considera as conexões dentro de cada grupo isoladamente, mesmo que alguns vértices do grupo tenham baixa conectividade com os demais.

- Exemplo: grupos baseados em densidade

- Subgrafo  $G_s(V_s, E_s)$  é  $\gamma$ -denso (quasi-clique), se  $\frac{|E_s|}{|V_s| \cdot (|V_s| - 1) / 2} \geq \gamma$





Exemplo: 5-quasi-clique e 4-quasi-clique sobrepostas

# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS

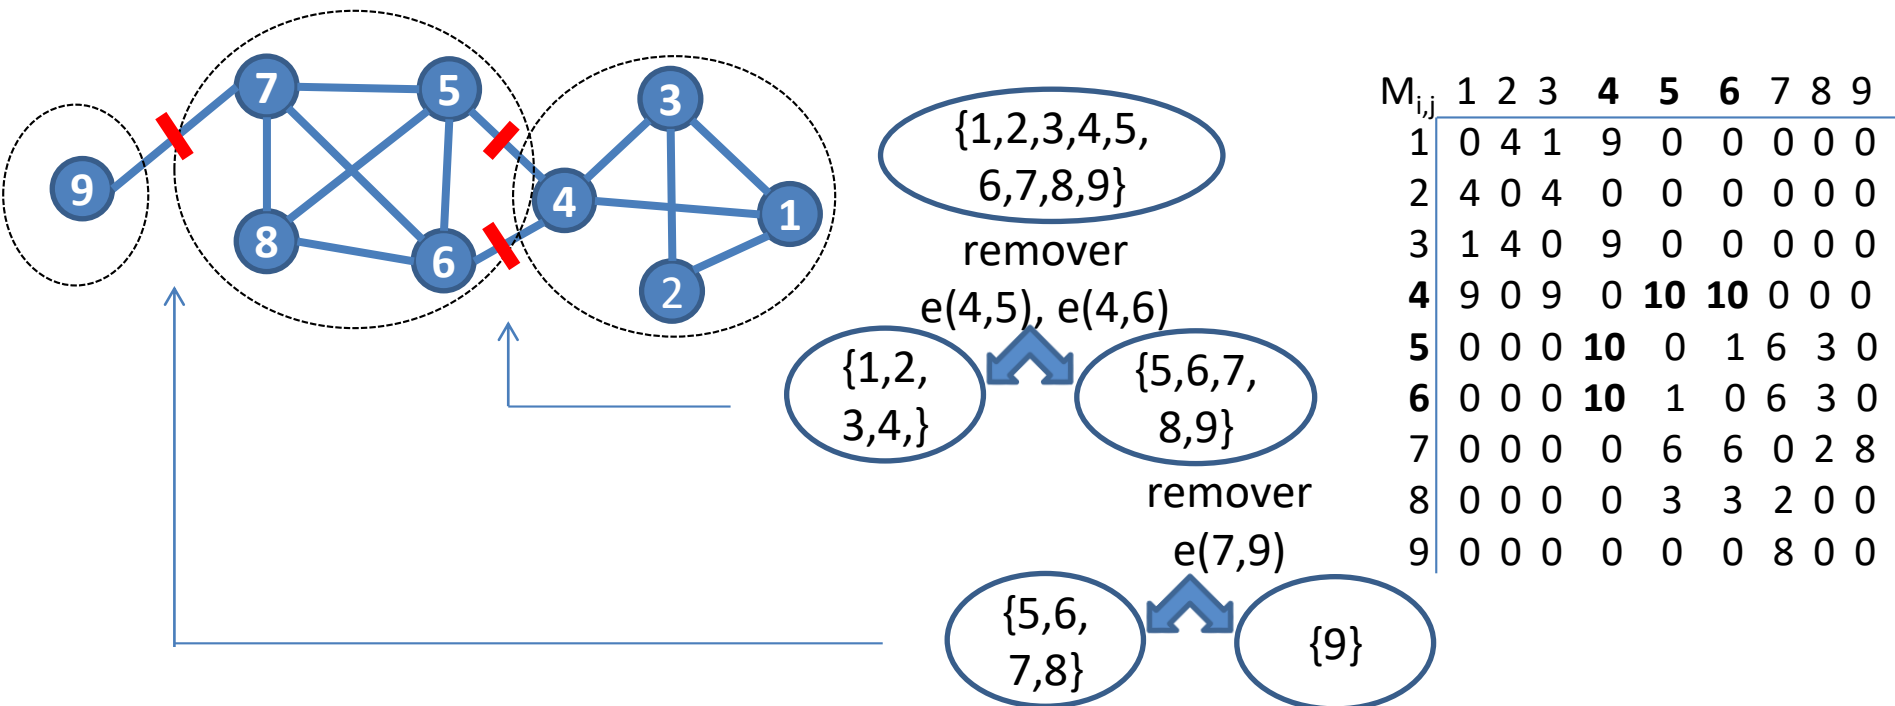
- Centrada em Rede
  - Considera a topologia de toda a rede, visando seu particionamento
    - Exemplo: redução de dimensionalidade, preservando a proximidade entre vértices baseada na conectividade da rede.



# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## DETECÇÃO DE COMUNIDADES – EXEMPLOS DE ABORDAGENS

- Centrada em Hierarquia
  - Cria grupos a partir da estrutura hierárquica dos nós
    - Exemplo: divide o grafo ao remover arestas com maior grau de intermediação (número de caminhos mais curtos que passam pela aresta)



# TAREFAS DE MINERAÇÃO – REDES COMPLEXAS

## EXEMPLOS DE FERRAMENTAS/RECURSOS

- Neo4j
- NetworkX
- Gephi
- Scikit-Learn
- ...



# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

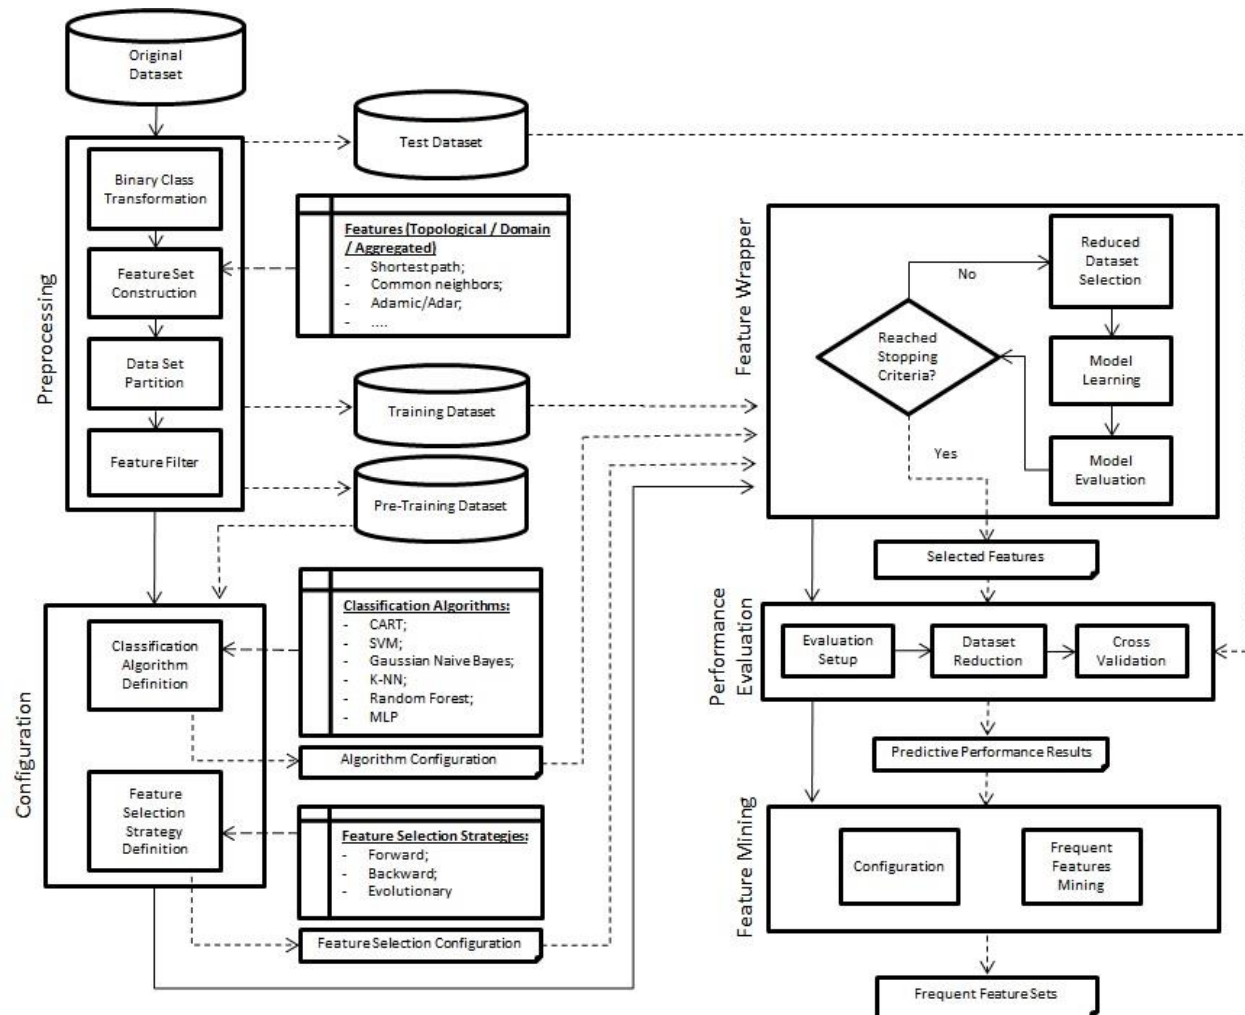
**6. CONSIDERAÇÕES FINAIS**

# EXEMPLOS DE PROJETOS

## PREDIÇÃO DE LIGAÇÕES – SELEÇÃO DE VARIÁVEIS

PREDLIG  
(Pecli et al., 2015)

Abordagem  
Supervisionada

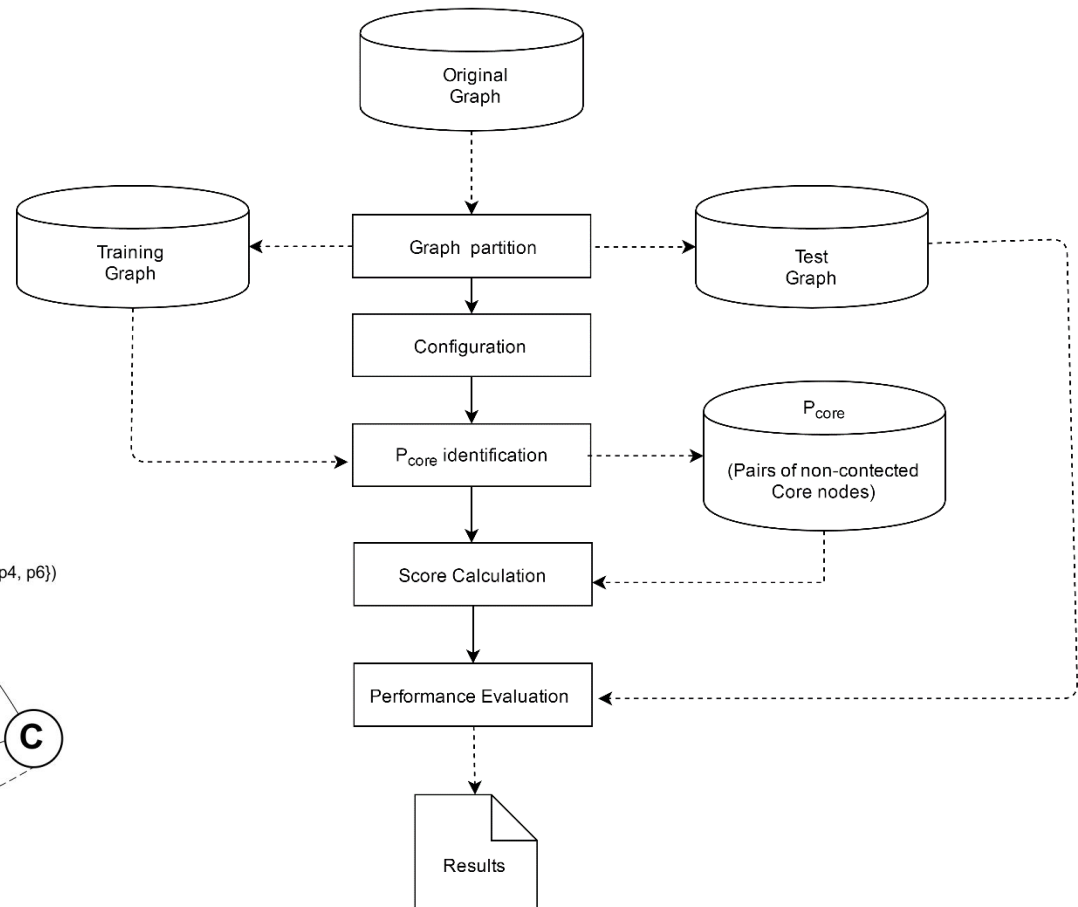
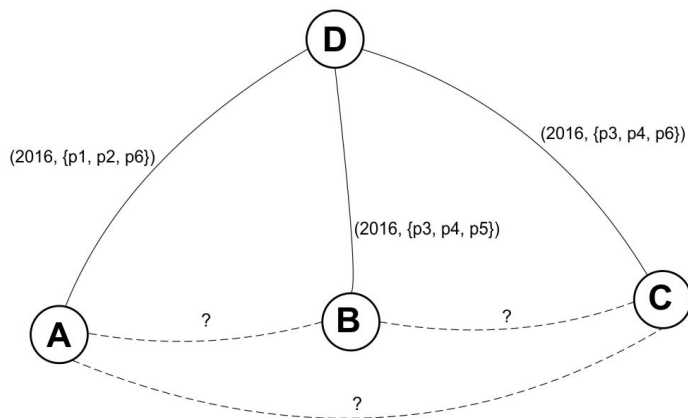


# EXEMPLOS DE PROJETOS

## PREDIÇÃO DE LIGAÇÕES – DADOS TEMPORAIS E CONTEXTUAIS

PREDLIG  
(Muniz, 2016)

Abordagem  
Não Supervisionada



# EXEMPLOS DE PROJETOS

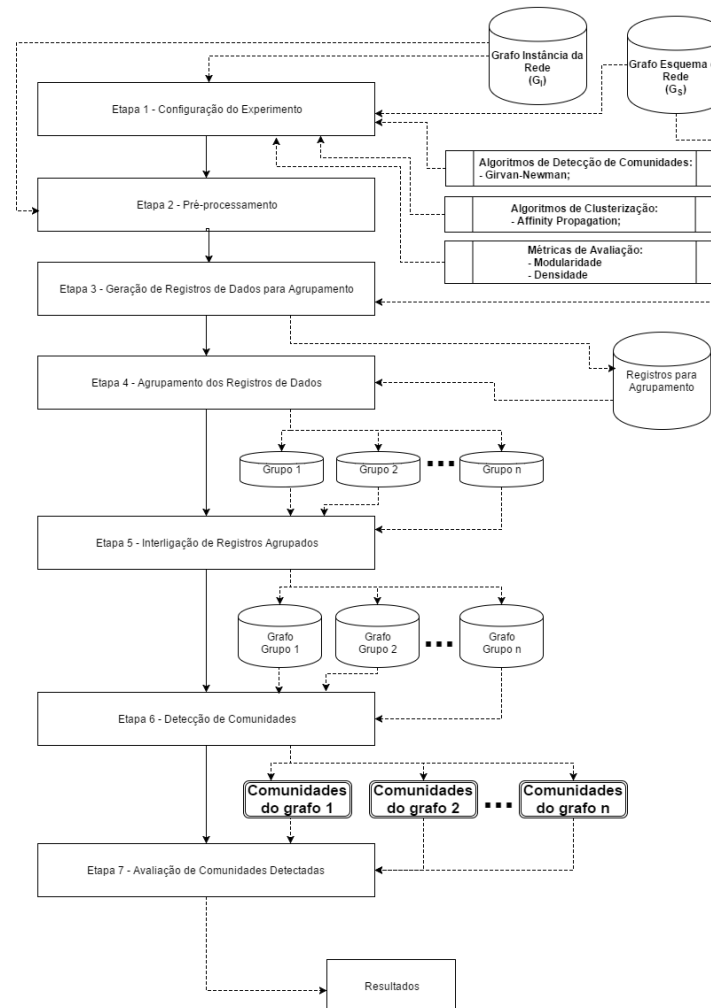
## DETECÇÃO DE COMUNIDADES – DADOS CONTEXTUAIS

DETCOM  
(Dias, 2016)

Clusterização

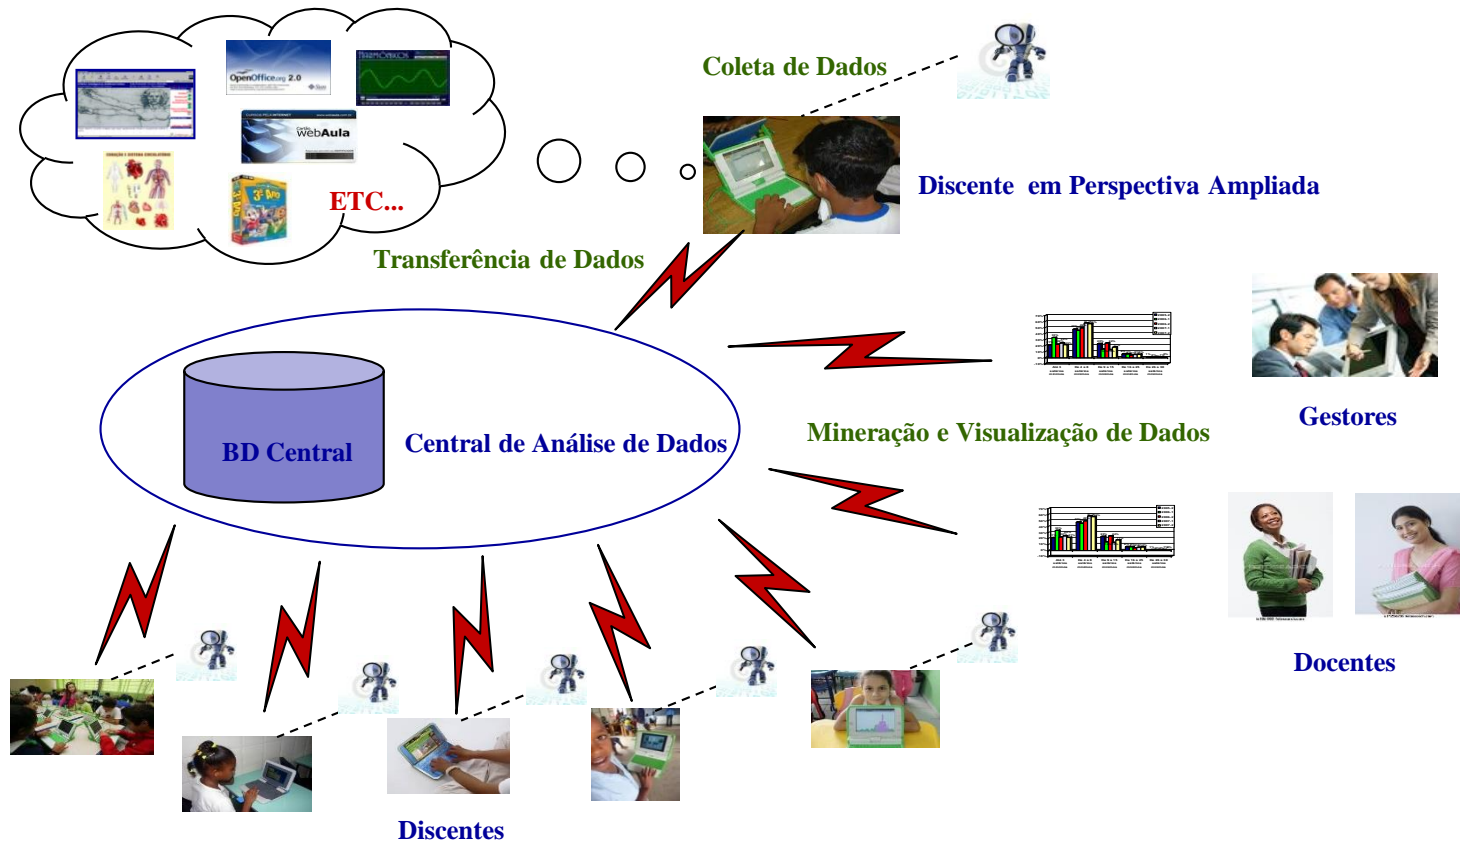
+

Deteccção de Comunidades



# EXEMPLOS DE PROJETOS

## EDUCAÇÃO: USO DE TECNOLOGIA



**Projeto MEMORE: Um Computador por Aluno (Goldschmidt et al., 2015)**

# EXEMPLOS DE PROJETOS

## EDUCAÇÃO: USO DE TECNOLOGIA

<i>Exemplos de Regras de Associação Identificadas nas Escolas Piloto de Pirai/RJ</i> <i>Anos: 2013 a 2015</i>	<i>Sup.</i>	<i>Conf.</i>
(R <sub>1</sub> ) Atuou em grupo, não utilizou para lazer e desenvolveu atividades escolares ==> Concluiu todas as atividades desenvolvidas	34	82
(R <sub>2</sub> ) Atuou em casa ==> Desenvolveu atividades escolares	15	43
(R <sub>3</sub> ) Atuou em casa ==> Desenvolveu atividade de lazer	16	46
(R <sub>4</sub> ) Atuou em grupo ==> Desenvolveu atividades escolares	33	100
(R <sub>5</sub> ) Desenvolveu atividade de Ciências ==> Conseguiu concluir atividade	24	82
(R <sub>6</sub> ) Desenvolveu atividade de Língua Portuguesa ==> Conseguiu concluir atividade	12	84

**Projeto MEMORE: Um Computador por Aluno (Goldschmidt et al., 2015)**

# ROTEIRO

**1. POSICIONAMENTO E MOTIVAÇÃO**

**2. CONCEITOS BÁSICOS**

**3. TAREFAS DE MINERAÇÃO CLÁSSICAS**

**4. TAREFAS DE MINERAÇÃO EM REDES COMPLEXAS**

**5. EXEMPLOS DE PROJETOS**

**6. CONSIDERAÇÕES FINAIS**

# CONSIDERAÇÕES FINAIS

## Recaptulando...

- **Redes Complexas**
  - Comportamento, propriedades e evolução
- **Análise de dados em Redes Complexas**
  - Uso de técnicas de Data Mining
- **Exemplos de tarefas de Data Mining em Redes Complexas**
  - Predição de Links e Detecção de Comunidades
- **Pesquisas na área**
  - Crescente e diversificado interesse
- **Objetivos da apresentação**
  - Expor conceitos básicos e comentar sobre algumas dessas pesquisas



# CONSIDERAÇÕES FINAIS

## Atividades em Ciência de Dados - uma Taxonomia



# CONSIDERAÇÕES FINAIS

## Exemplos de Temas de Pesquisa (Análise de Redes Complexas)

- **Aspectos Temporais e Contextuais na Evolução das Redes**
  - Propagação da Informação vs. Reputação e Confiança
- **Mineração de Textos**
  - Opinion Mining / Sentiment Analysis
- **Combinação de Tarefas**
  - Detecção de Comunidades + Predição de Links
- **Redes Heterogêneas**
  - Redes Multimodais e/ou Multidimensionais
- **Aplicações em IoT**
  - Interações entre as “coisas” → Infraestrutura e Semântica
- **Aplicações em Segurança da Informação**
  - Detecção de Botnets e de Social Bots

## BIBLIOGRAFIA SUGERIDA

- Faceli, K., Lorena, A. C., Gama, J., Carvalho, A. C. P. (2011) *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. Rio de Janeiro: LTC.
- Tan, P., Steinbach, M., Kumar, V. (2009) *Introdução ao Data Mining – Mineração de Dados*. Rio de Janeiro: Editora Ciência Moderna.
- Witten, I., Frank, E. (2005) *Data Mining: Practical Machine Learning Tools and Techniques*. San Francisco: Morgan Kaufmann.
- Goldschmidt, R., Bezerra, E., Passos, E. (2015) *Data Mining: Conceitos, Técnicas, Ferramentas, Orientações e Aplicações*. Rio de Janeiro: Elsevier.

## BIBLIOGRAFIA SUGERIDA

- Goldschmidt, R. R.; Fernandes, I. (Org.) ; Norris, M. (Org.). MEMORE: Um Ambiente Computacional para Coleta e Mineração de Dados sobre o Uso de Computadores na Educação. 1. ed. Rio de Janeiro: FAETEC, 2015. v. 1. 257p .
- Pecli, A. et al. Dimensionality Reduction for Supervised Learning in Link Prediction Problems. In: 17th International Conference on Enterprise Information Systems, 2015, Barcelona. *Proceedings of the 17th International Conference on Enterprise Information Systems*. v. 1. p. 295-301.
- Dias, M. V. *Uma abordagem para Detecção de Comunidades em Redes Complexas Baseada em Informações de Domínio* 2016. Dissertação (Mestrado em Engenharia de Defesa) – IME.

## BIBLIOGRAFIA SUGERIDA

- Muniz, C. P. *Investigando a Utilização de Atributos Temporais no Problema de Predição de Links*. 2016. Dissertação (Mestrado em Sistemas e Computação) – IME.
- Wang, P., Xu, B., Wu, Y., & Zhou, X. (2015). Link prediction in social networks: the state-of-the-art. *Science China Information Sciences*, 58, 1–38.
- Tang, L.; Liu, H. (2010) Community detection and mining in social media. *Synthesis Lectures on Data Mining and Knowledge Discovery*. v. 2, n. 1, p. 1–137.



FIM !