

Aprendizado Semi-Supervisionado usando Competição e Cooperação entre Partículas em Redes Complexas

Fabricio Breve
UNESP

<http://www.fabriciobreve.com>

Agenda

- Introdução
 - Aprendizado de Máquina
 - Aprendizado Semi-Supervisionado
 - Modelos Baseados em Grafos
- Competição e Cooperação entre Partículas em Redes
 - Descrição do Modelo
 - Resultados
- Extensões do Modelo
 - Detecção de Comunidades Sobrepostas
 - Aprendizado Semi-Supervisionado com Dados Imperfeitos
 - Segmentação de Imagens
- Conclusões

Introdução

Aprendizado de Máquina

Aprendizado Semi-Supervisionado

Modelos baseados em Grafos

Aprendizado de Máquina

- Disciplina que trata do projeto e desenvolvimento de algoritmos que melhoram automaticamente com a experiência, imitando o comportamento de aprendizado de humanos.
- Algumas das principais categorias:
 - Aprendizado Supervisionado
 - Aprendizado Não Supervisionado
 - **Aprendizado Semi-Supervisionado**



- Mitchell, T. *Machine Learning*. McGraw Hill, 1997.
- Alpaydin, E. *Introduction to machine learning*. MIT Press, 2004.
- Natarajan, B. K. *Machine learning: a theoretical approach*. Morgan Kaufmann, 1991.

Aprendizado Supervisionado

- Algoritmos deduzem uma função a partir dos dados de treinamento.
- Dados de treinamento consistem em pares de exemplos de entradas e saídas desejadas.
- **Objetivo:** obter uma função que seja capaz de prever a saída para qualquer entrada válida, após ter visto um número suficiente de exemplos de treinamento.

•Alpaydin, E. *Introduction to machine learning*. MIT Press, 2004.

•Duda, R. O., Hart, P. E., & Stork, D. G. *Pattern Classification* (2nd Edition). Wiley-Interscience, 2000.

Exemplo: Preço de uma casa



R\$ 350.000

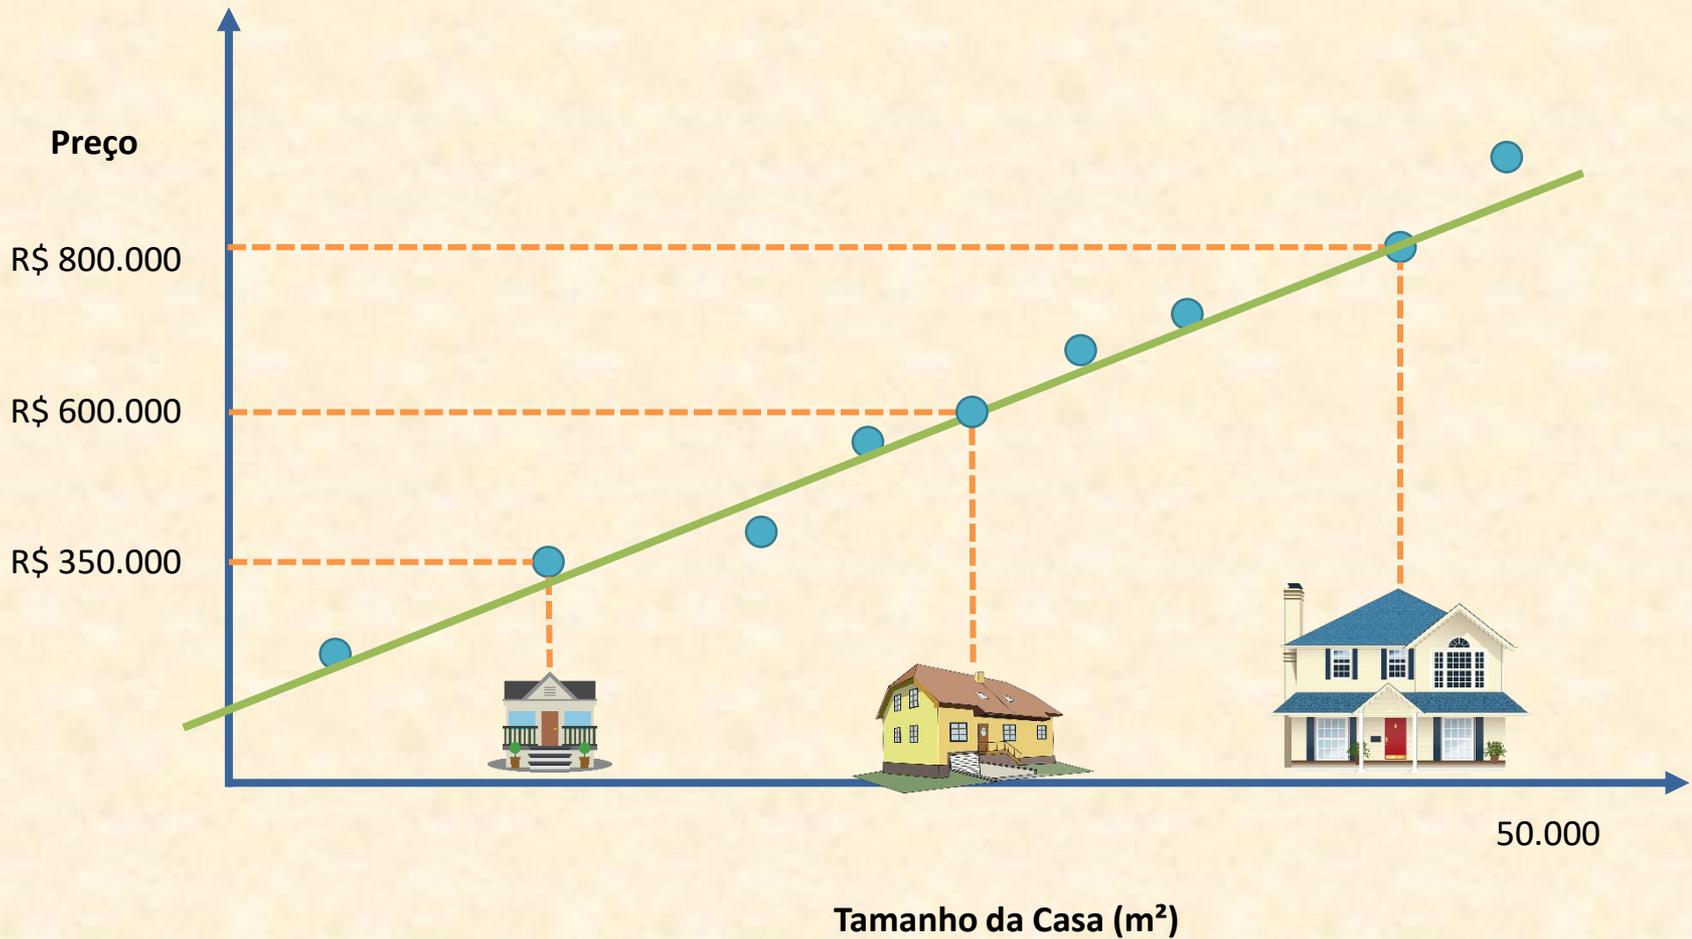


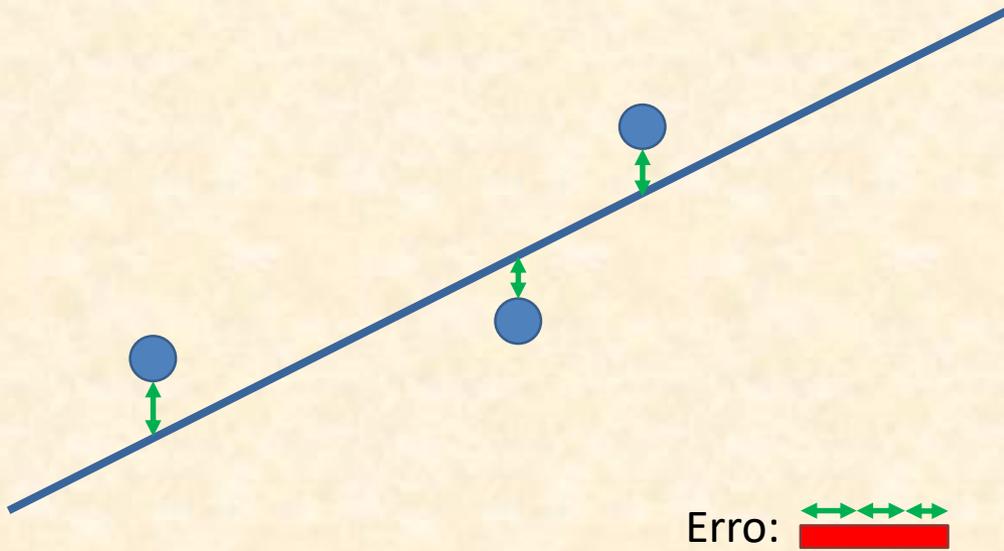
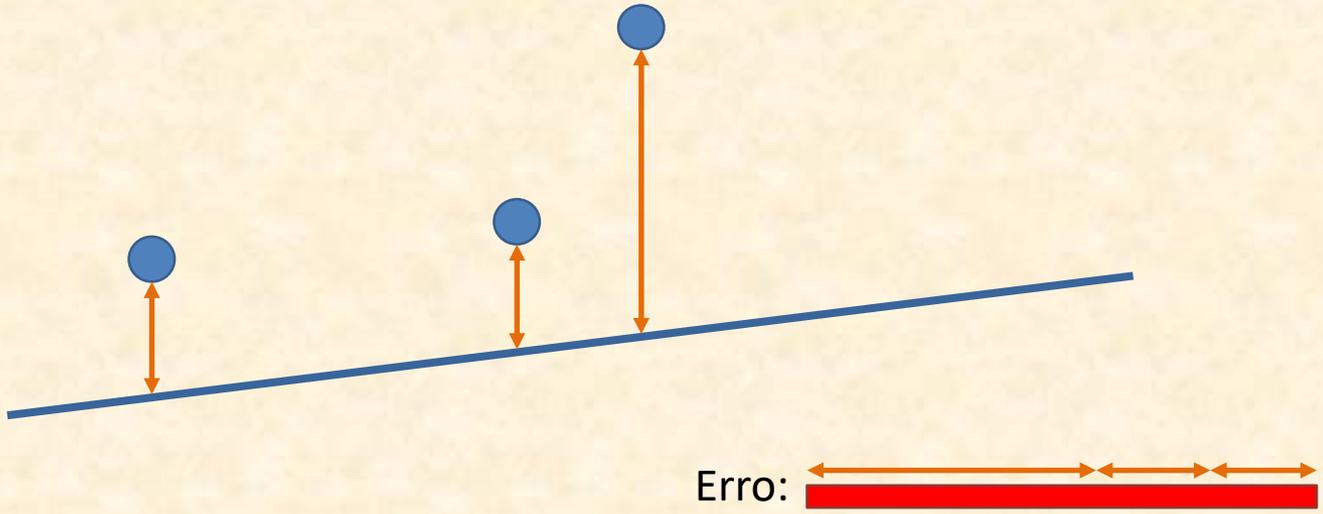
?



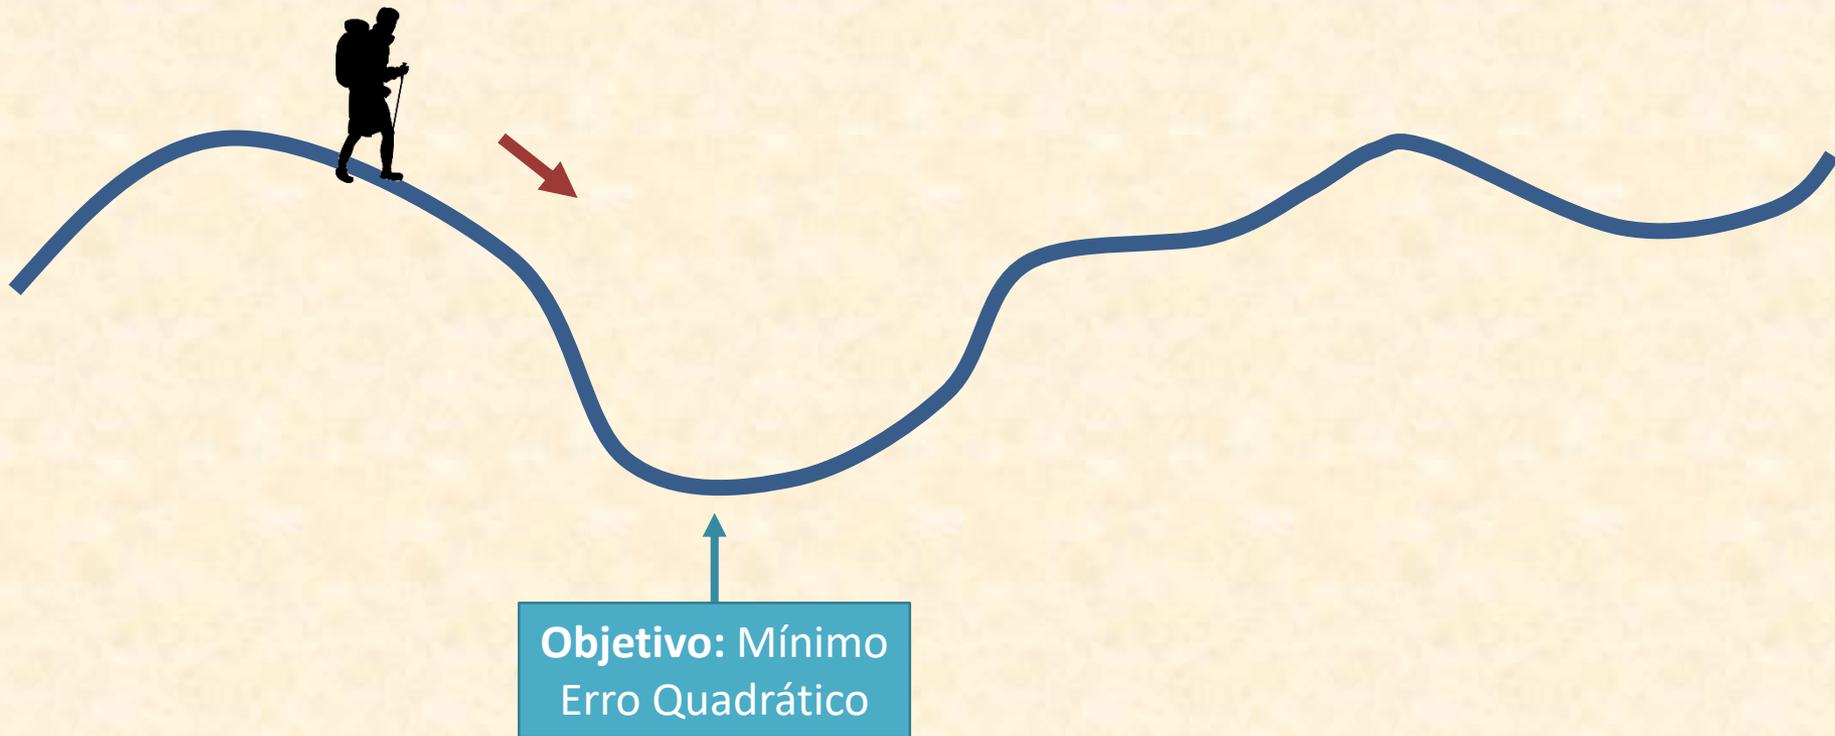
R\$ 800.000

Regressão Linear





Gradiente Descendente

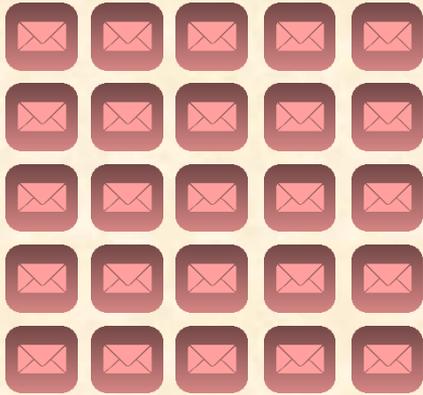


Exemplo: Detecção de SPAM



200 e-mails

Exemplo: Detecção de SPAM



SPAM



Não-SPAM

Classificamos 50 como SPAM
e 150 como Não-SPAM

Vamos procurar quantos desses e-mails tem a palavra

“réplica” 



SPAM



Não-SPAM

Questão: com base em nossos dados, se um e-mail contém a palavra “réplica”, qual a probabilidade de ser SPAM?

40%

60%

80%

Algoritmo Naive Bayes

- Podemos acrescentar outros atributos:
 - “réplica” → 80%
 - “grátis” → 65%
 - “barato” → 60%
 - erro de ortografia → 70%
 - falta linha de assunto → 90%
 - etc.
- Combinando essas probabilidades individuais podemos obter classificadores mais confiáveis.

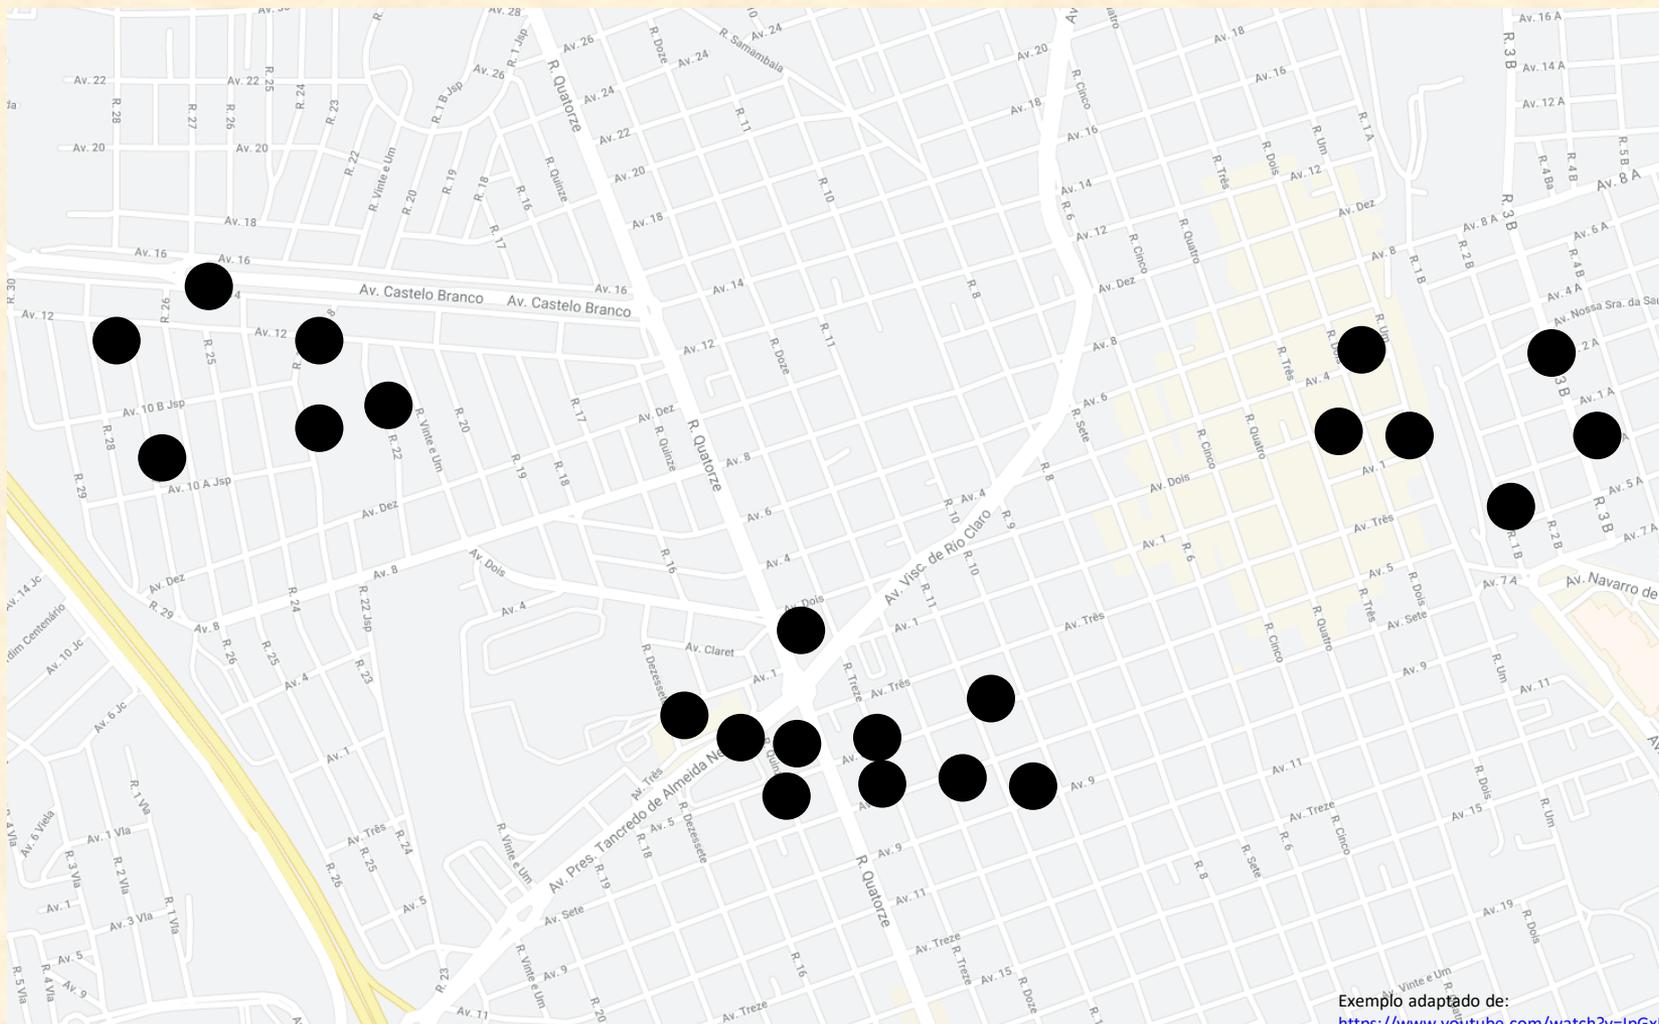
Aprendizado Não Supervisionado

- Algoritmos buscam determinar como os dados estão organizados.
- Dados de treinamento consistem apenas de exemplos de entrada, sem rótulos ou valores de saída.
- Objetivo: encontrar padrões no espaço de entradas.
 - Uma das formas de atingir este objetivo é observar quais são as regiões com maior e menor densidade de dados.

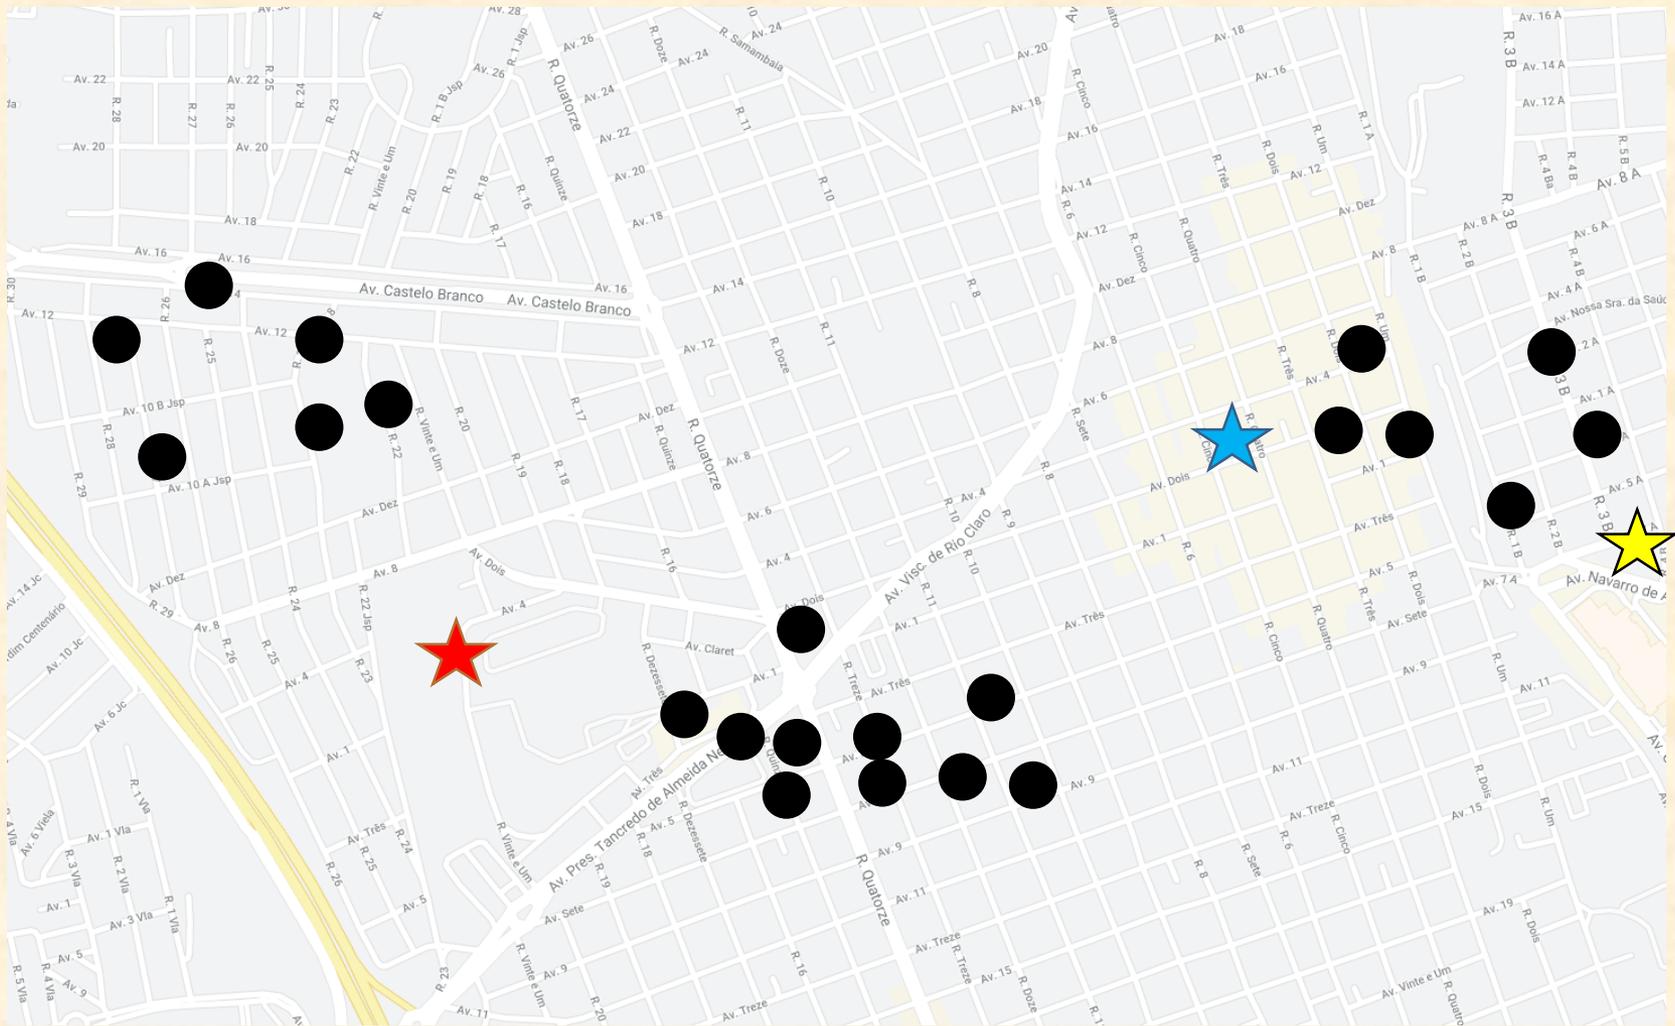
•Alpaydin, E. *Introduction to machine learning*. MIT Press, 2004.

•Duda, R. O., Hart, P. E., & Stork, D. G. *Pattern Classification* (2nd Edition). Wiley-Interscience, 2000.

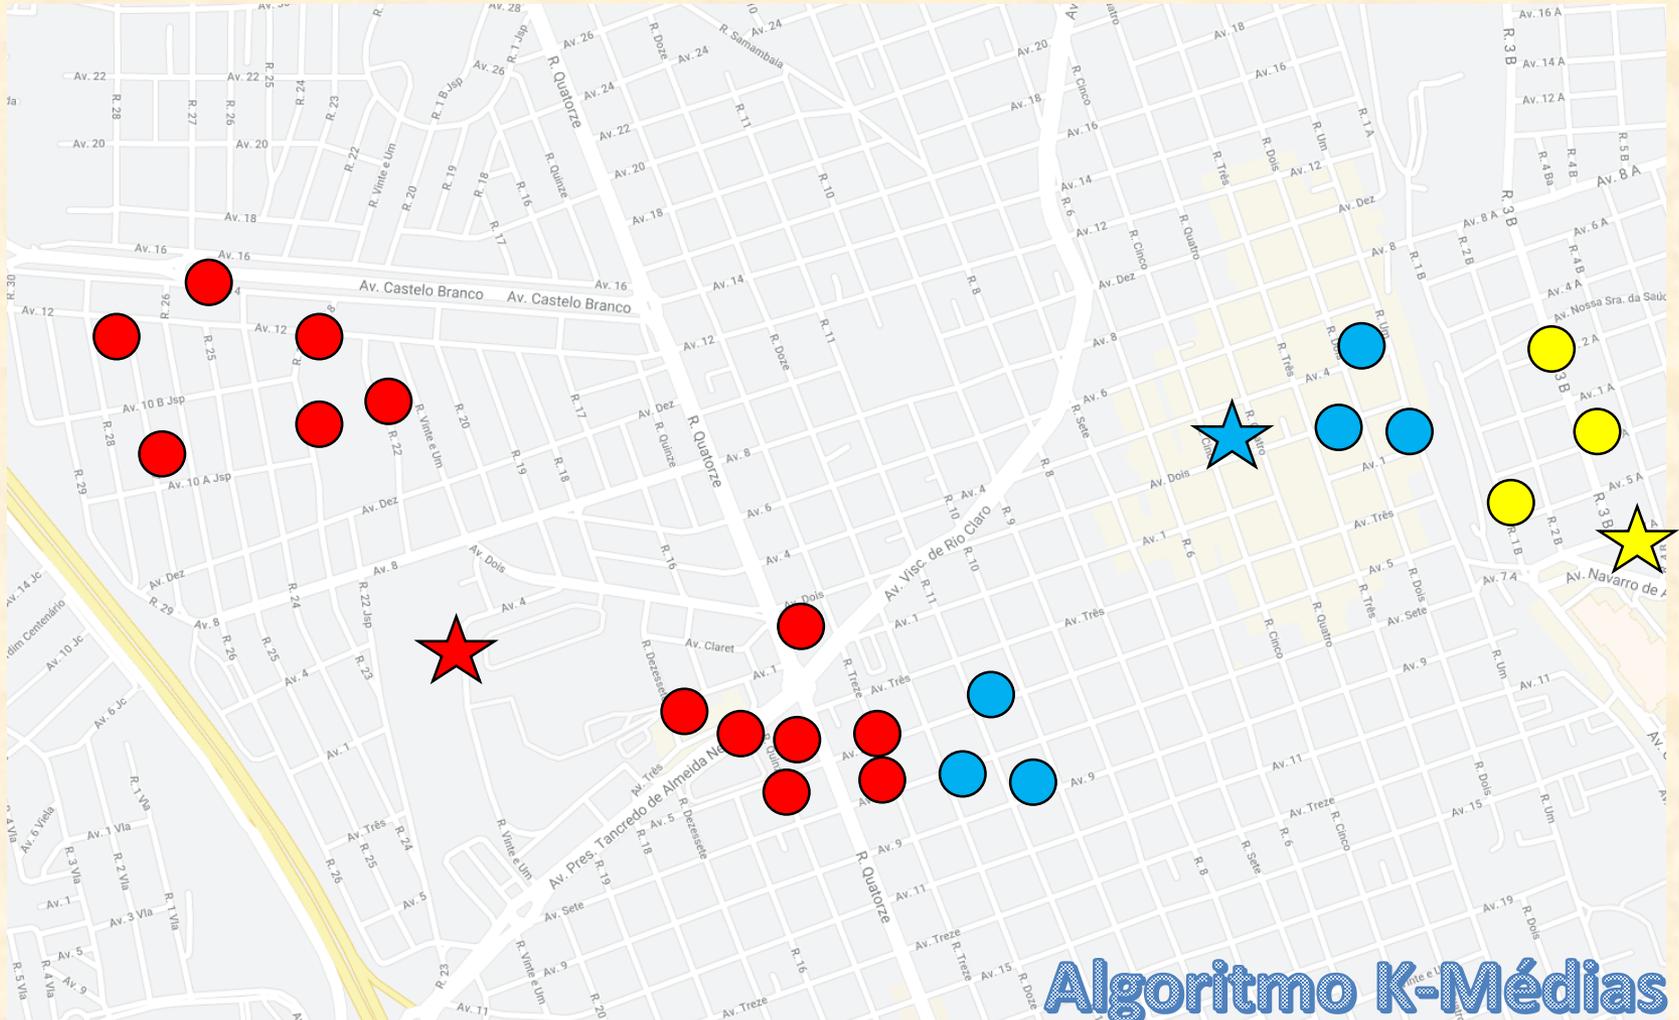
Onde abrir pizzarias?



Onde abrir pizzarias?



Onde abrir pizzarias?



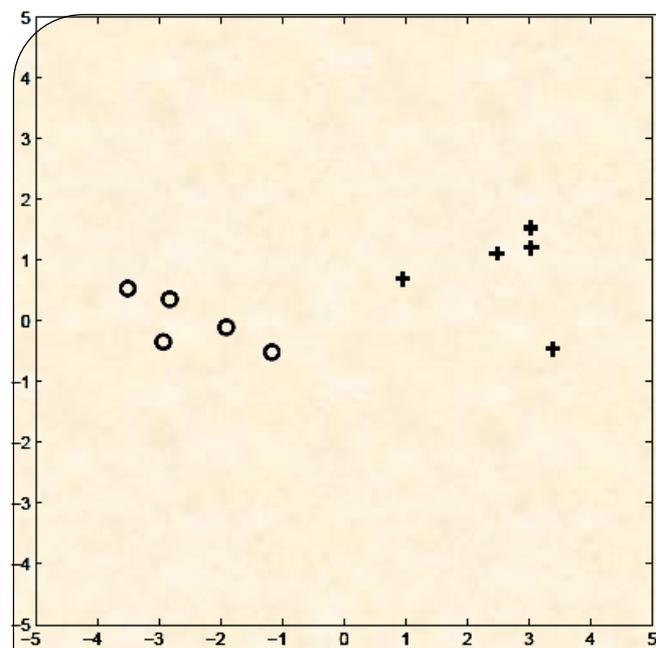
Aprendizado Semi-Supervisionado

- Algoritmos fazem uso tanto de dados rotulados quanto de dados não rotulados para o treinamento.
 - Normalmente poucos dados rotulados e bastante dados não rotulados.
- Objetivo: fornecer rótulos para os dados não rotulados.
- Em muitos casos, o uso de alguns dados rotulados em meio aos dados não rotulados melhora consideravelmente a precisão do aprendizado.

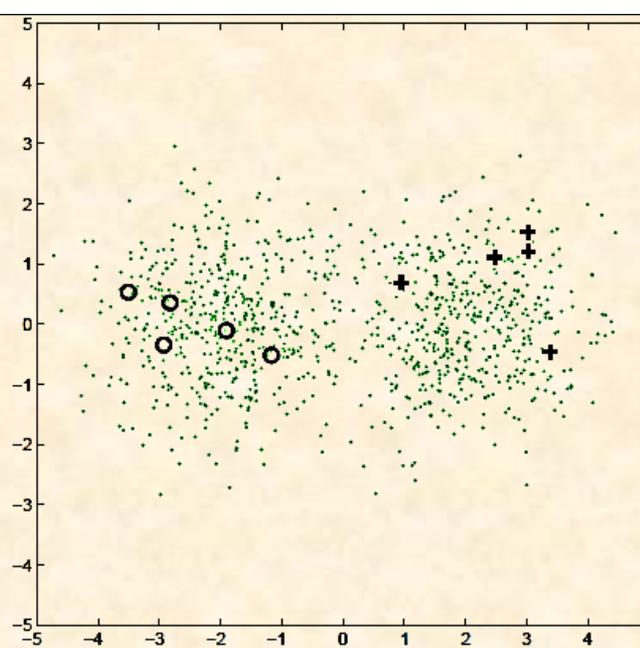
•Zhu, X. *Semi-Supervised Learning Literature Survey*. Technical Report 1530, Computer Sciences, University of Wisconsin-Madison, 2005.

•Chapelle, O., Schölkopf, B., & Zien, A., Eds. *Semi-Supervised Learning. Adaptive Computation and Machine Learning*. Cambridge, MA: The MIT Press, 2006.

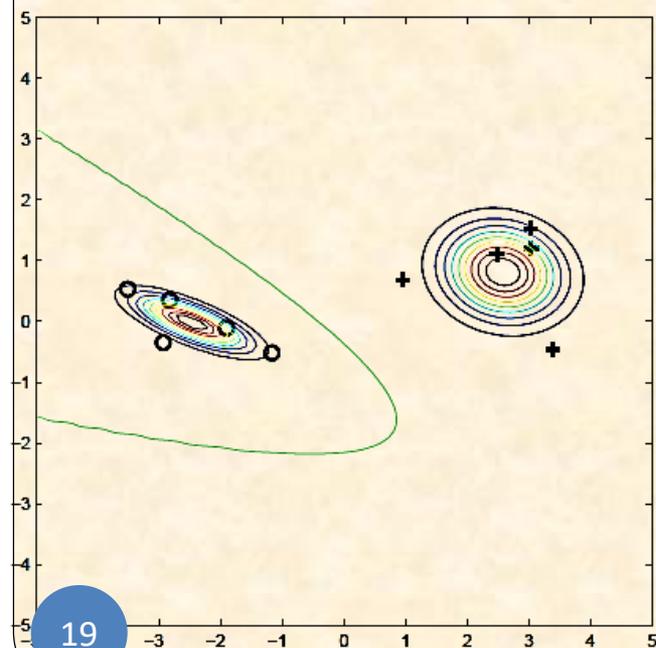
•Abney, S. *Semisupervised Learning for Computational Linguistics*. CRC Press, 2008.



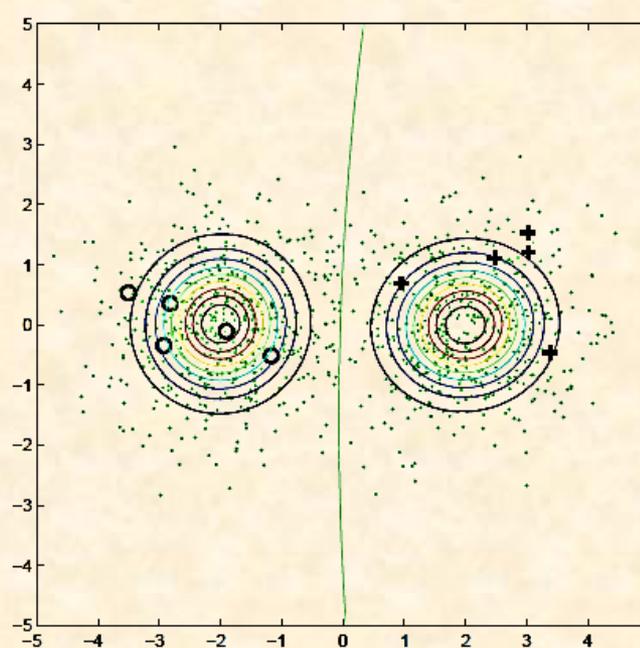
(a)



(b)



(c)



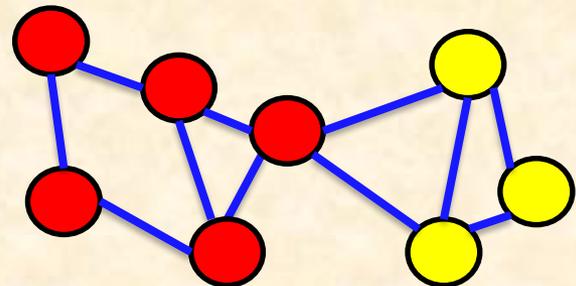
(d)

Um problema de classificação binário em aprendizado semi-supervisionado. Se assumirmos que cada classe tem distribuição Gaussiana, podemos usar os dados não rotulados para ajudar a estimar os parâmetros: (a) dados rotulados; (b) dados rotulados e não rotulados; (c) modelo aprendido a partir dos dados rotulados; (d) modelo aprendido a partir dos dados rotulados e não rotulados

X. Zhu, "Semi-supervised learning literature survey," Computer Sciences, University of Wisconsin-Madison, Tech. Rep. 1530, 2005.

Métodos Baseados em Grafos

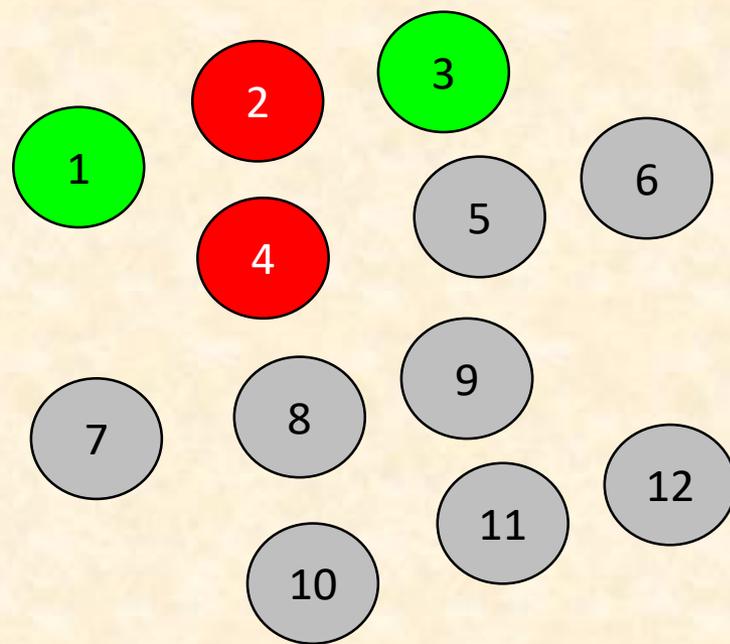
- Área de pesquisa mais ativa em aprendizado semi-supervisionado.
- Dados são representados por nós de um grafo, onde as arestas são rotuladas com a distância entre os pares de nós.
- Nós rotulados são usados para propagar informação de rótulo para os demais.
- Métodos assumem suavidade de rótulos através do grafo.



Exemplo: Alunos aprovados em vestibular

ID	Nota ENEM	Média do Histórico	Situação
1	743	8,2	Aprovado
2	358	6,3	Reprovado
3	826	9,1	Aprovado
4	412	7,1	Reprovado
5	915	8,9	?
6	873	8,9	?
7	520	7,5	?
8	297	5,9	?
9	358	7,2	?
10	884	8,8	?
11	725	9,0	?
12	612	7,7	?

- Cada aluno é um nó do grafo
- Vamos conectar cada nó com seus 3 vizinhos mais próximos usando a **distância euclidiana**



Primeiro vamos normalizar os dados

Dados normalizados: média 0, desvio padrão 1

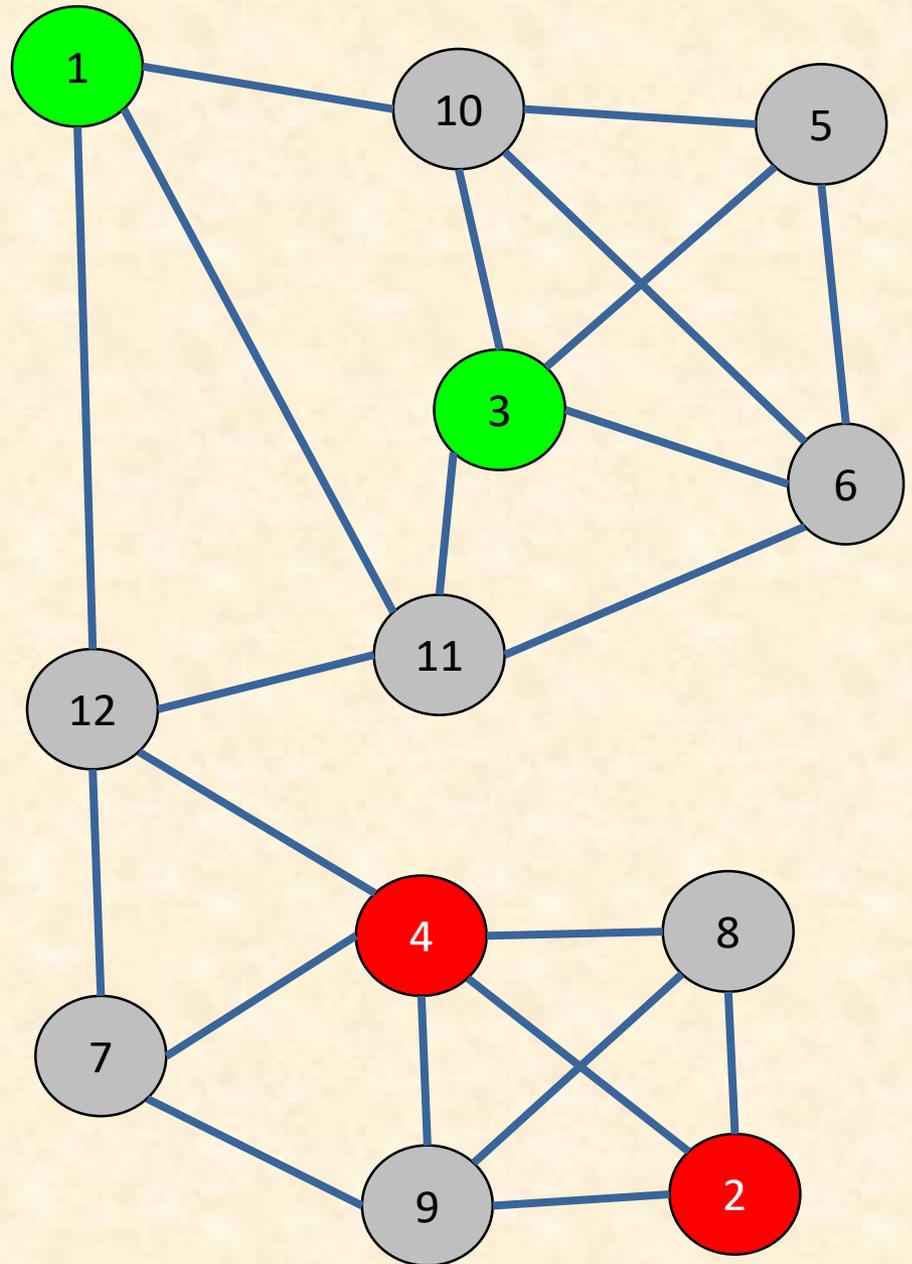
ID	Nota ENEM	Média do Histórico	Situação
1	743	8,2	Aprovado
2	358	6,3	Reprovado
3	826	9,1	Aprovado
4	412	7,1	Reprovado
5	915	8,9	?
6	873	8,9	?
7	520	7,5	?
8	297	5,9	?
9	358	7,2	?
10	884	8,8	?
11	725	9,0	?
12	612	7,7	?

ID	Nota ENEM	Média do Histórico	Situação
1	0,50	0,29	Aprovado
2	-1,17	-1,43	Reprovado
3	0,86	1,10	Aprovado
4	-0,93	-0,71	Reprovado
5	1,25	0,92	?
6	1,07	0,92	?
7	-0,46	-0,35	?
8	-1,43	-1,79	?
9	-1,17	-0,62	?
10	1,12	0,83	?
11	0,43	1,01	?
12	-0,06	-0,17	?

ID	Nota ENEM	Média do Histórico	ENEM norm. (x)	Média norm. (y)	Situação
1	743	8,2	0,50	0,29	Aprovado
2	358	6,3	-1,17	-1,43	Reprovado
3	826	9,1	0,86	1,10	Aprovado
4	412	7,1	-0,93	-0,71	Reprovado
5	915	8,9	1,25	0,92	?
6	873	8,9	1,07	0,92	?
7	520	7,5	-0,46	-0,35	?
8	297	5,9	-1,43	-1,79	?
9	358	7,2	-1,17	-0,62	?
10	884	8,8	1,12	0,83	?
11	725	9,0	0,43	1,01	?
12	612	7,7	-0,06	-0,17	?

$$d(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

	1	2	3	4	5	6	7	8	9	10	11	12
1		2,40	0,89	1,75	0,98	0,85	1,16	2,84	1,90	0,82	0,73	0,73
2	2,40		3,25	0,76	3,37	3,25	1,29	0,45	0,81	3,21	2,92	1,68
3	0,89	3,25		2,55	0,43	0,27	1,96	3,70	2,66	0,37	0,45	1,57
4	1,75	0,76	2,55		2,72	2,58	0,59	1,20	0,25	2,56	2,19	1,02
5	0,98	3,37	0,43	2,72		0,18	2,13	3,82	2,87	0,16	0,83	1,71
6	0,85	3,25	0,27	2,58	0,18		1,99	3,69	2,71	0,10	0,65	1,57
7	1,16	1,29	1,96	0,59	2,13	1,99		1,74	0,75	1,97	1,62	0,44
8	2,84	0,45	3,70	1,20	3,82	3,69	1,74		1,21	3,66	3,36	2,13
9	1,90	0,81	2,66	0,25	2,87	2,71	0,75	1,21		2,70	2,28	1,19
10	0,82	3,21	0,37	2,56	0,16	0,10	1,97	3,66	2,70		0,71	1,54
11	0,73	2,92	0,45	2,19	0,83	0,65	1,62	3,36	2,28	0,71		1,27
12	0,73	1,68	1,57	1,02	1,71	1,57	0,44	2,13	1,19	1,54	1,27	



Competição e Cooperação entre Partículas em Redes

Descrição do Modelo

Resultados

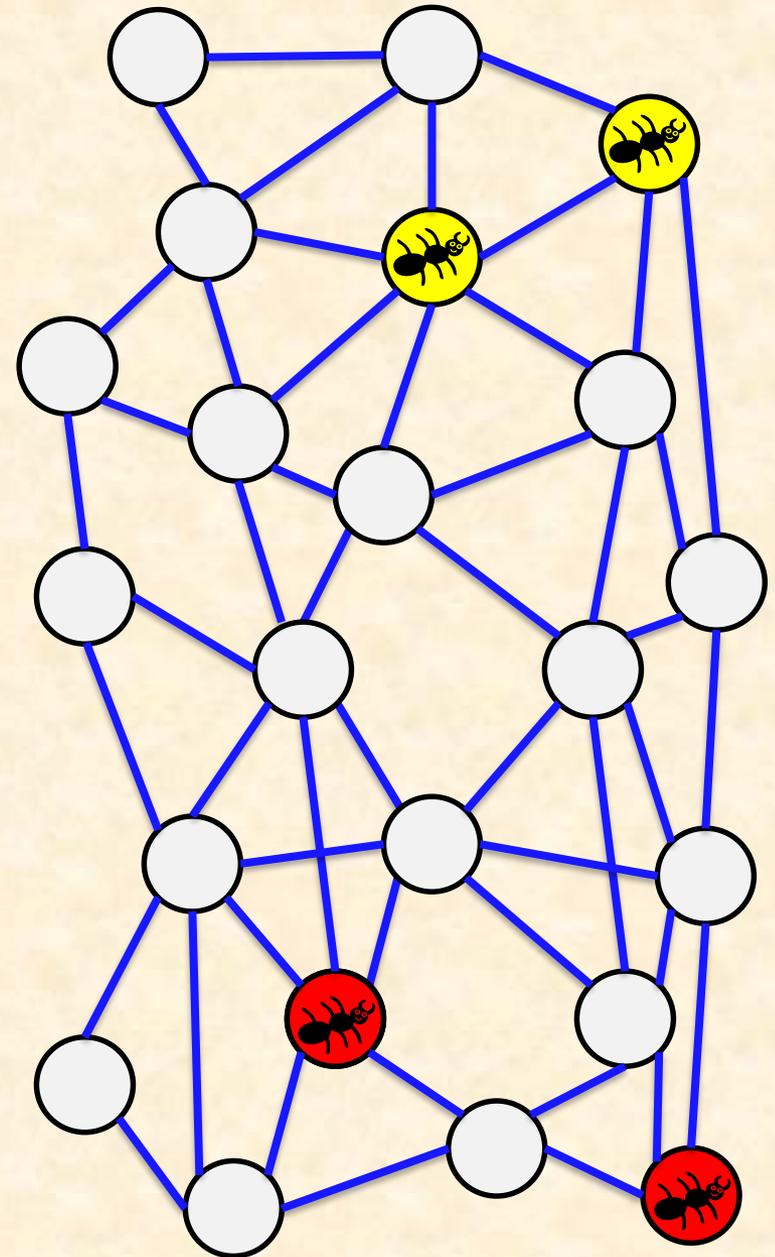
Competição e Cooperação entre Partículas em Redes Complexas

- Aplicação em Aprendizado Semi-Supervisionado.
- Competição e cooperação entre partículas na rede, combinado em um esquema único.
 - Cooperação:
 - Partículas da mesma classe caminham pela rede de maneira cooperativa, propagando seus rótulos.
 - Objetivo: Dominar a maior quantidade de nós possível.
 - Competição:
 - Partículas de classes diferentes competem entre si para determinar as bordas das classes.
 - Objetivo: Evitar a invasão de partículas de outros times.

BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves; PEDRYCZ, Witold; LIU, Jimming. **Particle competition and cooperation in networks for semi-supervised learning.** *IEEE Transactions on Knowledge and Data Engineering*, v.24, p.1686 - 1698, 2012.
<http://dx.doi.org/10.1109/TKDE.2011.119>

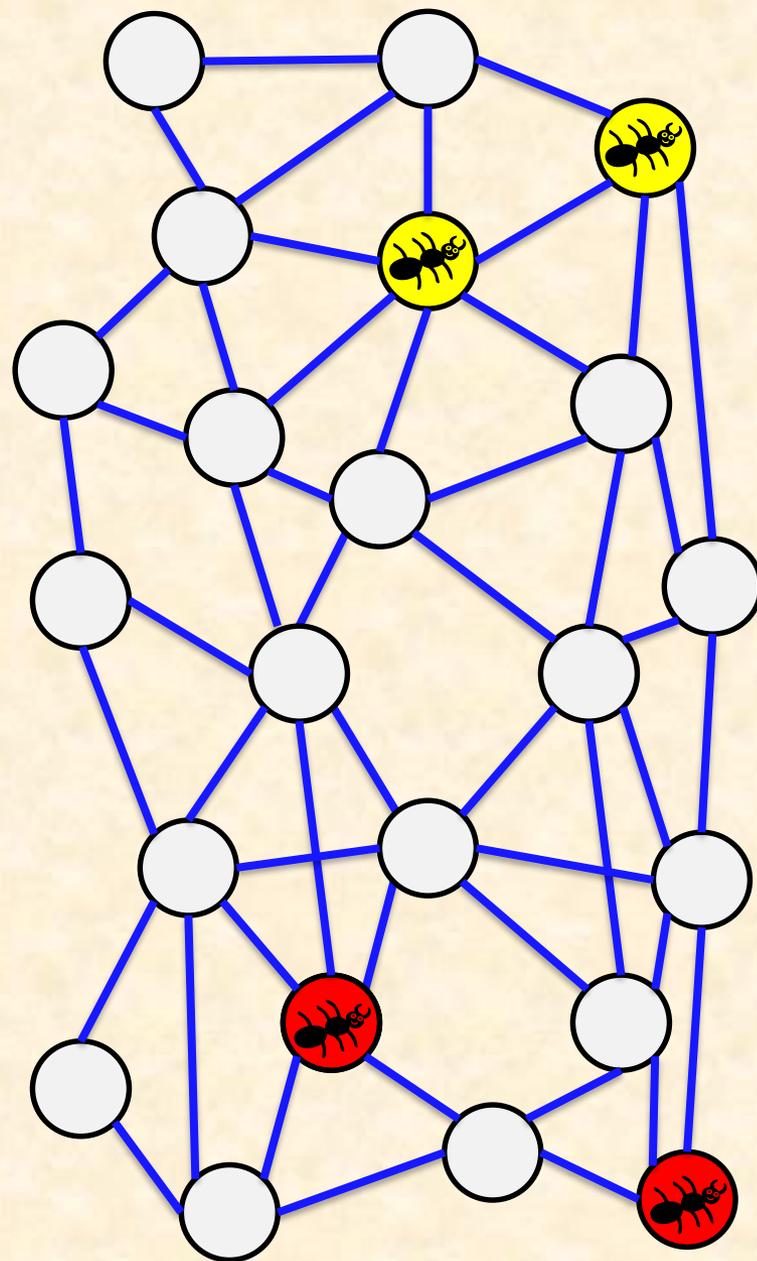
Configuração Inicial dos Nós

- Transforma-se a base de dados em uma rede não direcionada sem peso.
- Para cada item de dado é gerado um nó na rede.
- As arestas podem ser geradas usando uma das duas formas:
 - Cada nó é conectado aos vizinhos cuja distância é menor que um limiar σ
 - **Cada nó é conectado aos seus k vizinhos mais próximos.**



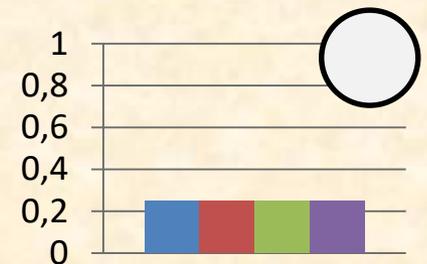
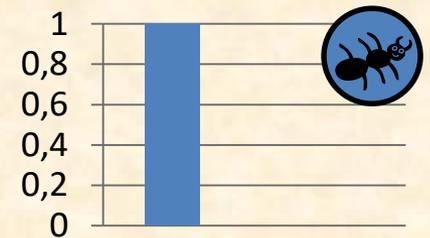
Configuração Inicial das Partículas

- Uma partícula é gerada para cada nó rotulado na rede
 - Este nó será o *nó casa* da partícula correspondente
- A posição inicial de cada partícula é ajustada para seu respectivo nó casa
- Partículas com o mesmo rótulo jogam para o mesmo time



Configuração Inicial dos Nós

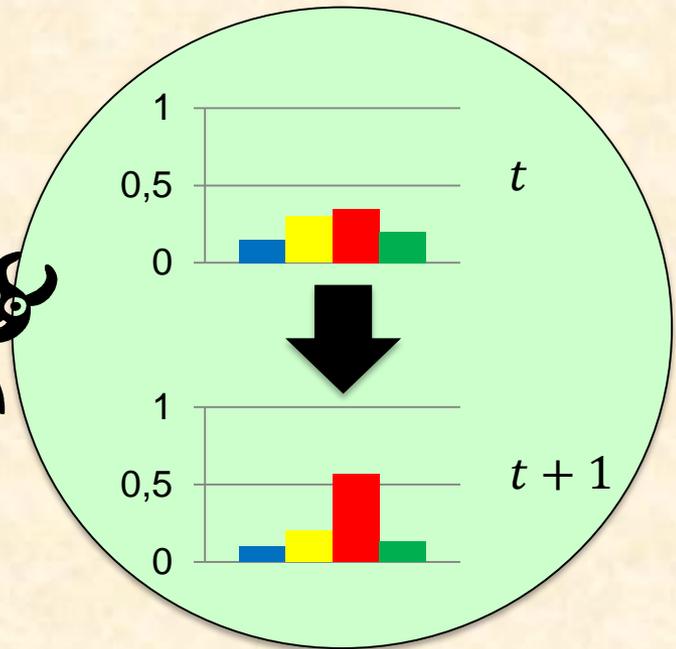
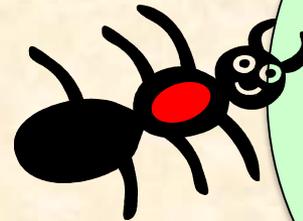
- Cada nó tem um vetor de domínio:
 - Nós rotulados tem níveis de domínio configurados para seus respectivos times.
 - Ex: $[1 \ 0 \ 0 \ 0]$ (4 classes, nó rotulado como classe A)
 - Nós não rotulados têm níveis de domínio configurados igualmente para cada time.
 - Ex: $[0.25 \ 0.25 \ 0.25 \ 0.25]$ (4 classes, nó não rotulado)



$$v_i^{\omega \ell} = \begin{cases} 1 & \text{se } x_i \text{ é rotulado e } y_i = \ell \\ 0 & \text{se } x_i \text{ é rotulado e } y_i \neq \ell \\ 1/c & \text{se } x_i \text{ não é rotulado} \end{cases}$$

Dinâmica de Nós

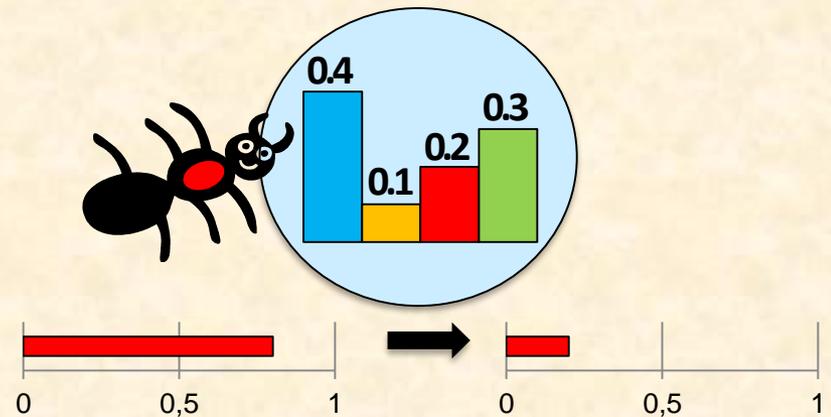
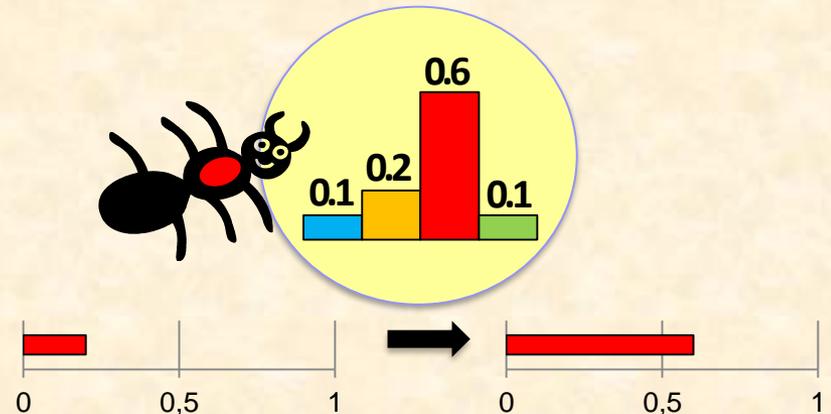
- Quando uma partícula seleciona um vizinho para visitar, ela...
 - Diminui o nível de domínio de outros times nesse vizinho.
 - Aumenta o nível de domínio de seu próprio time nesse vizinho.
- Exceção:
 - Níveis de domínio de nós rotulados são fixos.



$$v_i^{\omega_\ell}(t+1) = \begin{cases} \max\left\{0, v_i^{\omega_\ell}(t) - \frac{\Delta_v \rho_j^\omega(t)}{c-1}\right\} & \text{se } x_i \text{ não é rotulado e } \ell \neq \rho_j^f \\ v_i^{\omega_\ell}(t) + \sum_{q \neq \ell} v_i^{\omega_q}(t) - v_i^{\omega_q}(t+1) & \text{se } x_i \text{ não é rotulado e } \ell = \rho_j^f \\ v_i^{\omega_\ell}(t) & \text{se } x_i \text{ é rotulado} \end{cases}$$

Dinâmica de Partículas

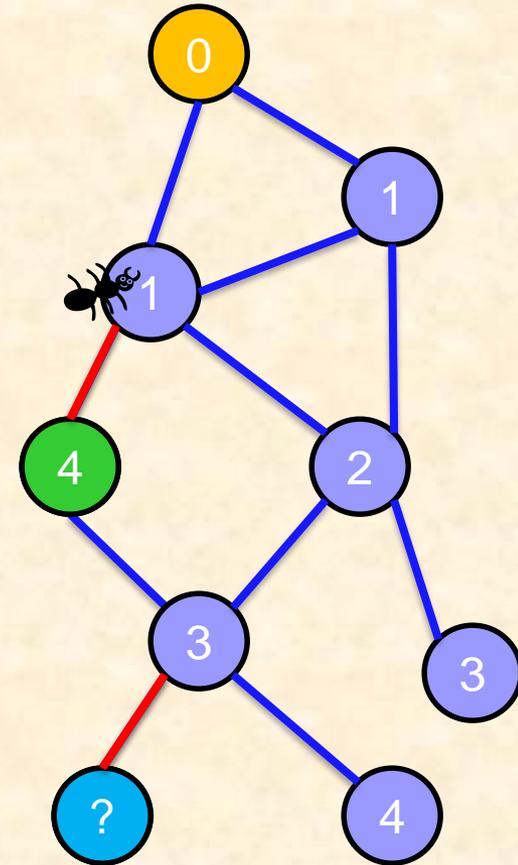
- Uma partícula se torna:
 - Forte quando ela visita um nó dominado por seu time
 - Fraca quando ela visita um nó dominado por outro time



$$\rho_j^\omega(t+1) = v_i^{\omega_\ell}(t+1)$$

Tabela de Distância

- Mantém a partícula informada da distância para seu nó casa
 - Evita que a partícula perca toda sua força caminhando em territórios inimigos
 - Mantém as partículas por perto para proteger sua própria vizinhança
- Atualizada automaticamente com informação local
 - Não requer nenhum cálculo a priori



$$\rho_j^{d_k}(t+1) = \begin{cases} \rho_j^{d_i}(t) + 1 & \text{se } \rho_j^{d_i}(t) + 1 < \rho_j^{d_k}(t) \\ \rho_j^{d_k}(t) & \text{caso contrário} \end{cases}$$

Caminhada Aleatório-Gulosa

- Caminhada Aleatória

- A partícula escolhe aleatoriamente qualquer vizinhos para visitar sem preocupação com o nível de domínio
- Probabilidades iguais para todos os vizinhos

$$p(v_i|\rho_j) = \frac{W_{qi}}{\sum_{\mu=1}^n W_{q\mu}}$$

CAMINHADA ALEATÓRIA

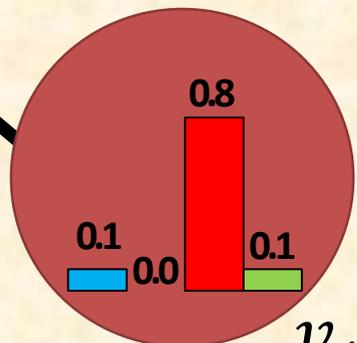
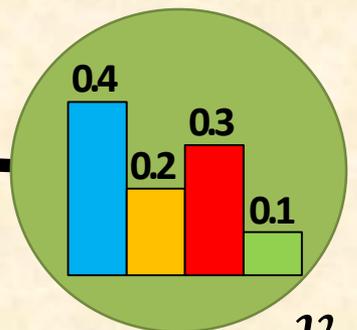
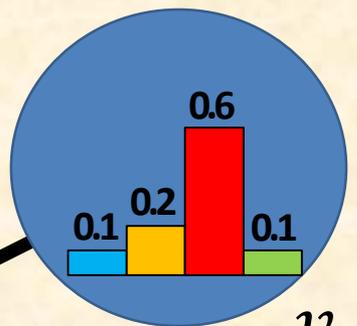
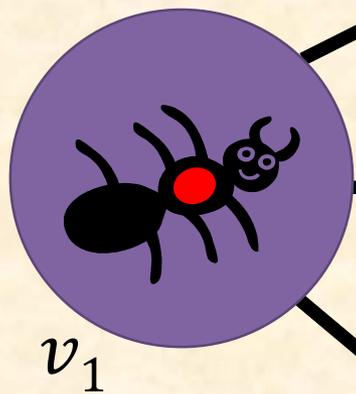
- Caminhada Gulosa

- A partícula prefere visitar nós que ela já domina e nós mais próximos de seu nó casa
- Probabilidade de visitar cada vizinho dada pelo nível de domínio e distância

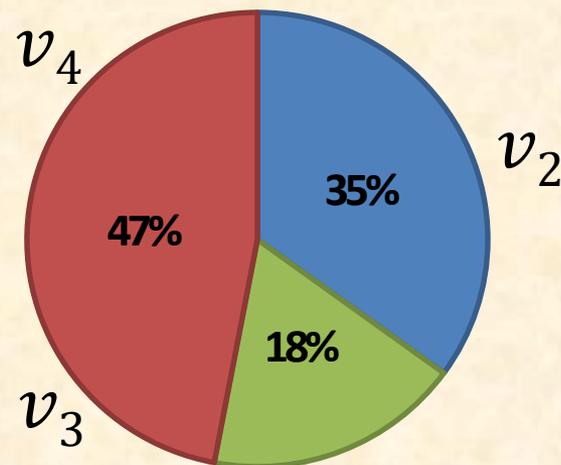
$$p(v_i|\rho_j) = \frac{W_{qi} v_i^{\omega_\ell} (1 + \rho_j^{d_i})^{-2}}{\sum_{\mu=1}^n W_{q\mu} v_\mu^{\omega_\ell} (1 + \rho_j^{d_\mu})^{-2}}$$

CAMINHADA GULOSA

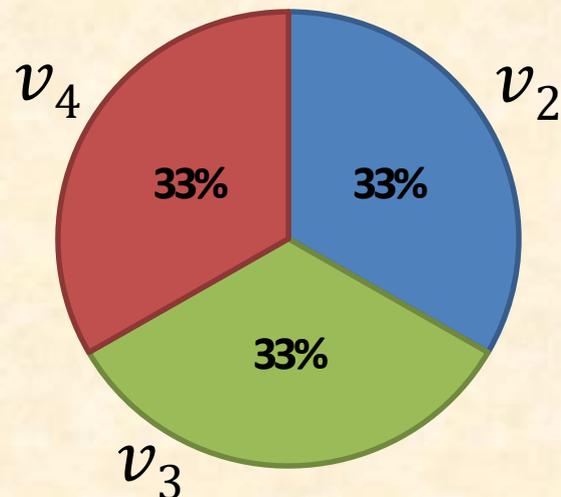
As partículas precisam exibir ambos os movimentos para que haja um equilíbrio entre o comportamento exploratório e o defensivo



Probabilidades no Movimento Guloso

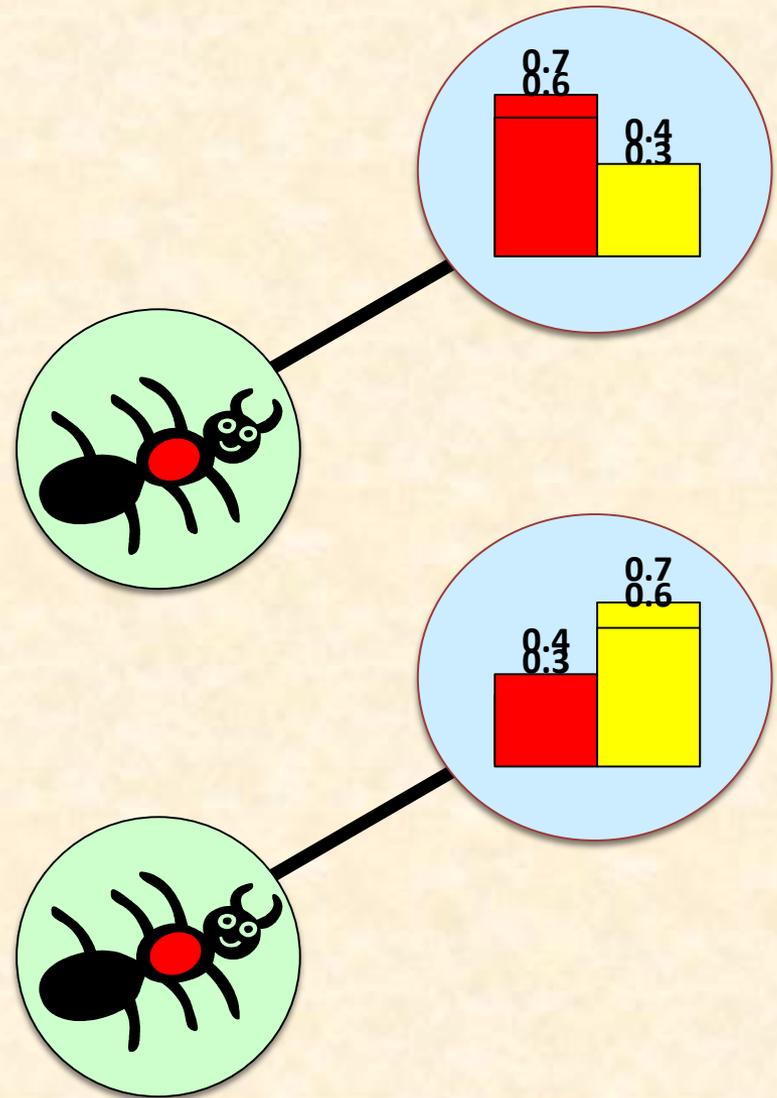


Probabilidades no Movimento Aleatório



Choques

- Uma partícula fica no nó visitado somente se o nível de domínio de seu time é maior que o dos outros;
- Caso contrário, um choque acontece e a partícula é expulsa, voltando ao nó onde estava anteriormente até a próxima iteração.



Algoritmo

Construir a rede;

Configurar os níveis de domínio;

Configurar posição inicial de partículas e seus correspondentes nós-casa;

Configurar força da partícula e distância;

Repita

Para cada partícula **faça**

Selecione movimento aleatório ou guloso;

Selecione o nó a ser visitado;

Atualize os níveis de domínio do nó visitado;

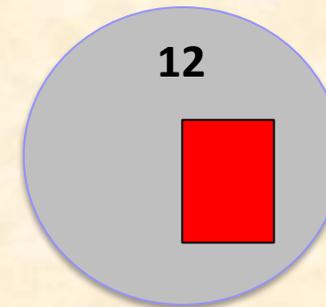
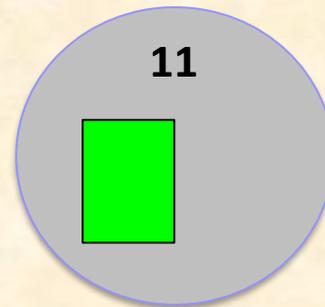
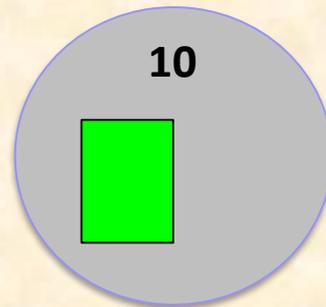
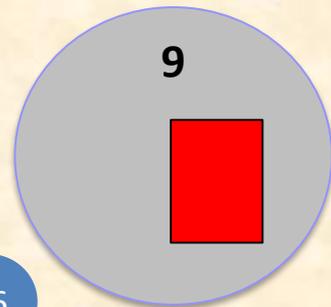
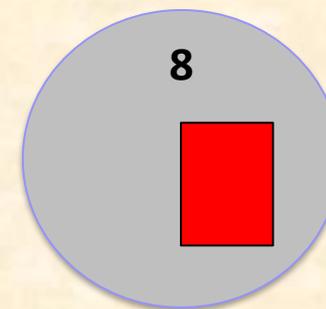
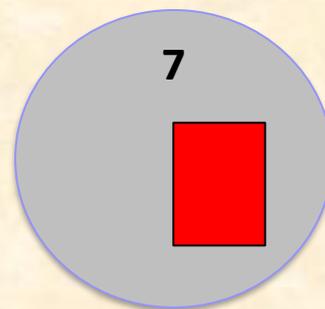
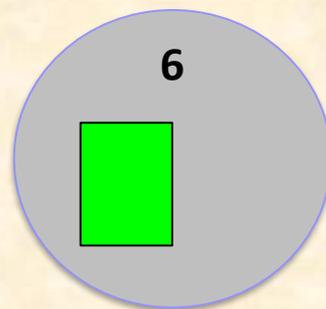
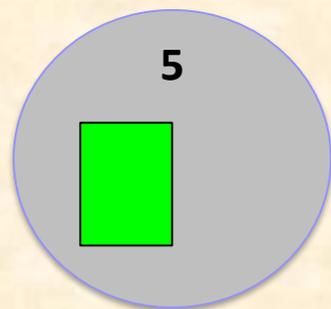
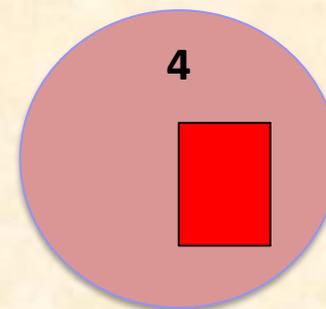
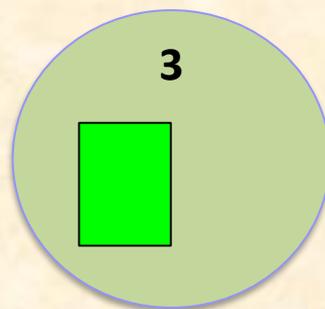
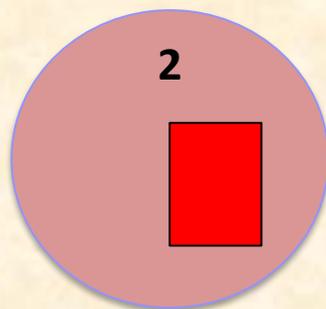
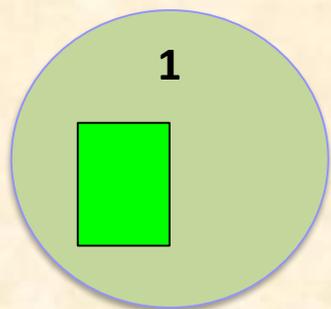
Atualize a força da partícula;

Atualize a tabela de distâncias;

Até que o critério de parada ou um número pré-definido de passos seja atingido;

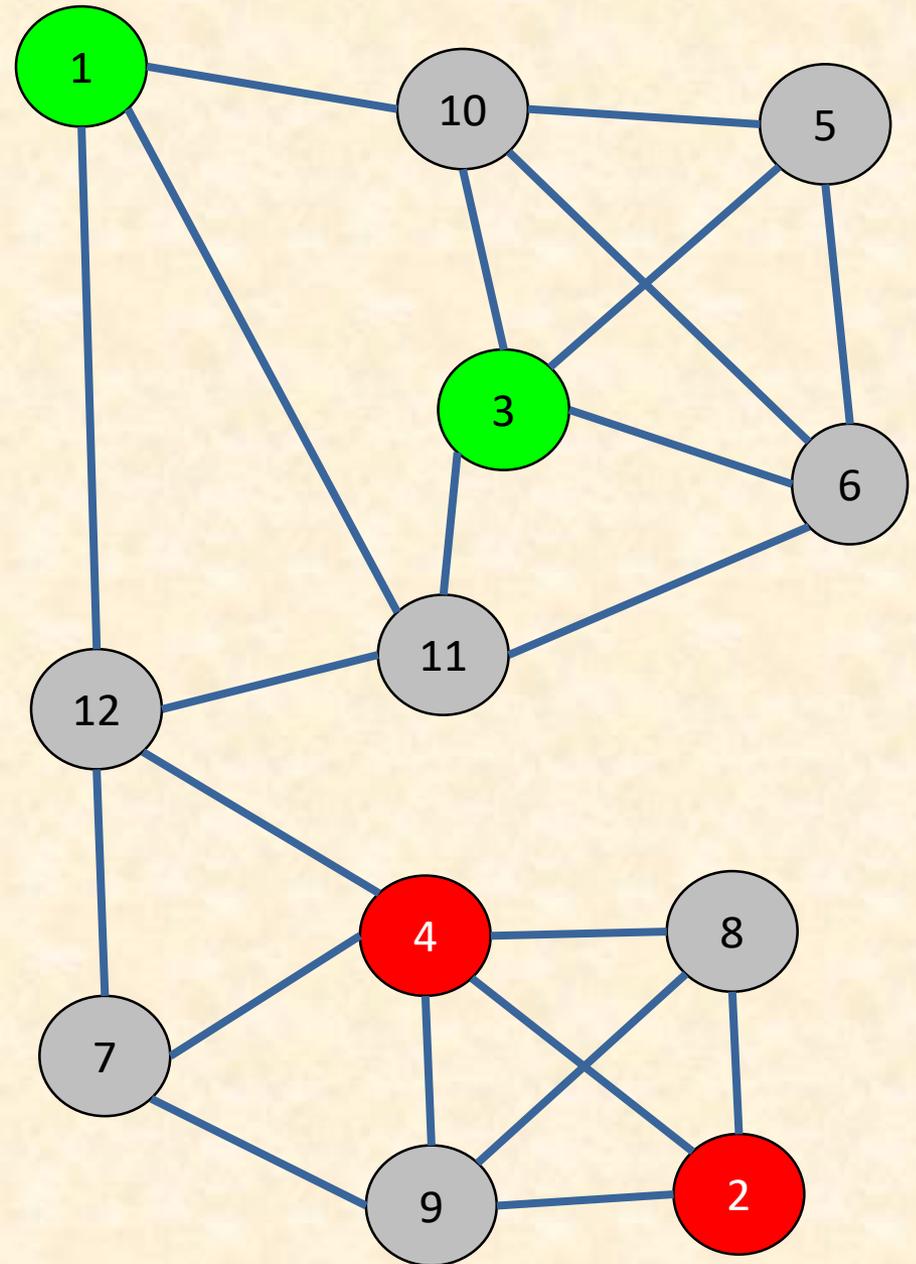
Rotule cada nó não rotulado de acordo com o time de partículas que tiver o maior domínio.

Voltando ao nosso exemplo dos alunos.
No final das iterações...



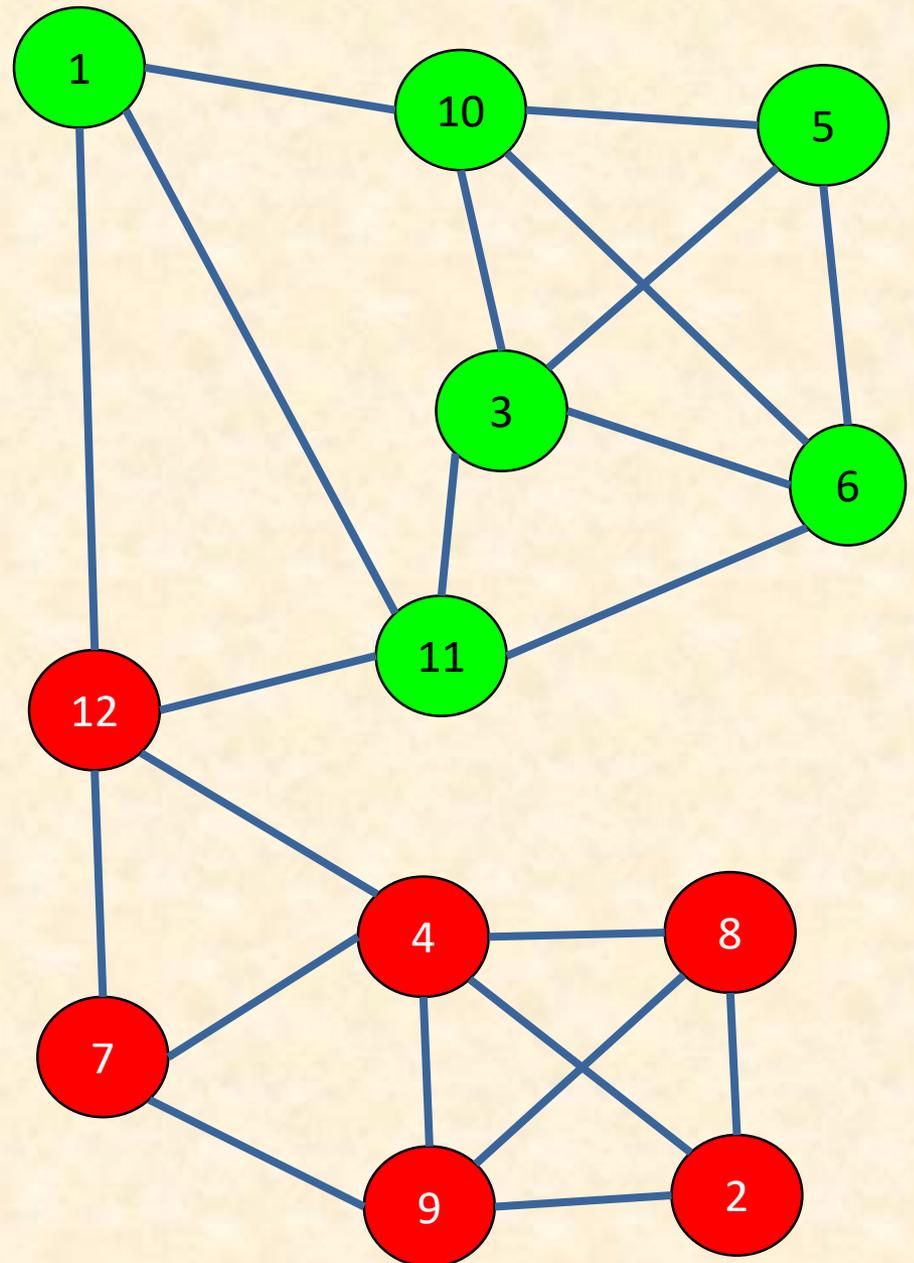
ID	Nota ENEM	Média do Histórico	ENEM norm. (x)	Média norm. (y)	Situação
1	743	8,2	0,50	0,29	Aprovado
2	358	6,3	-1,17	-1,43	Reprovado
3	826	9,1	0,86	1,10	Aprovado
4	412	7,1	-0,93	-0,71	Reprovado
5	915	8,9	1,25	0,92	?
6	873	8,9	1,07	0,92	?
7	520	7,5	-0,46	-0,35	?
8	297	5,9	-1,43	-1,79	?
9	358	7,2	-1,17	-0,62	?
10	884	8,8	1,12	0,83	?
11	725	9,0	0,43	1,01	?
12	612	7,7	-0,06	-0,17	?

Agora é só “pintar” os nós com a classe das partículas que o dominaram...



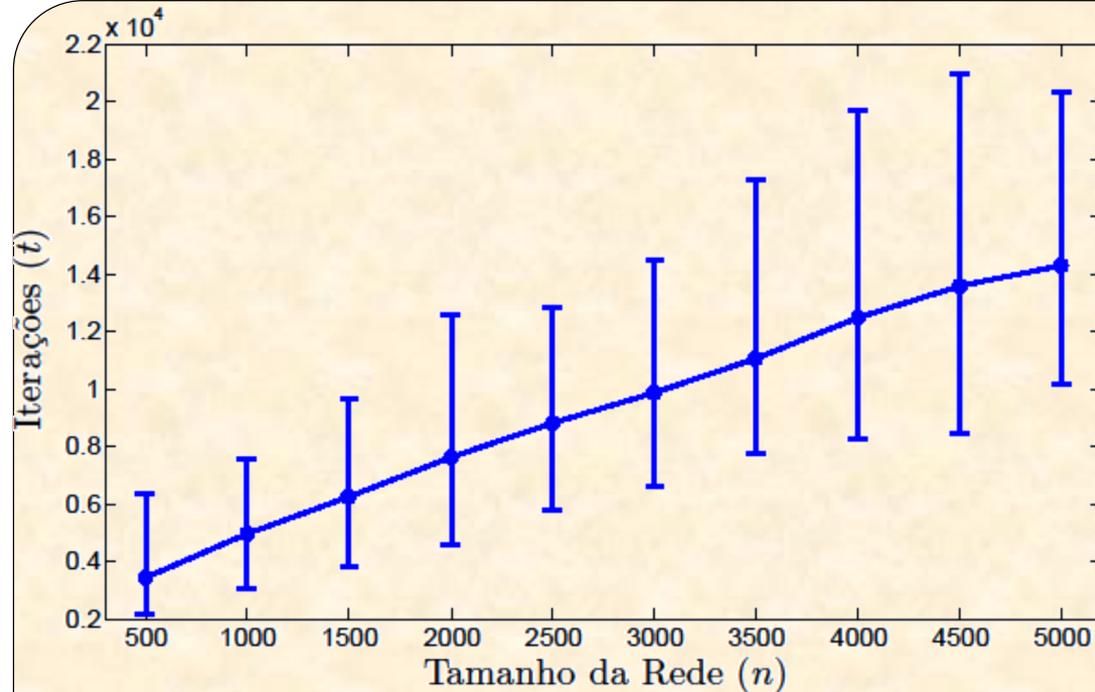
ID	Nota ENEM	Média do Histórico	ENEM norm. (x)	Média norm. (y)	Situação
1	743	8,2	0,50	0,29	Aprovado
2	358	6,3	-1,17	-1,43	Reprovado
3	826	9,1	0,86	1,10	Aprovado
4	412	7,1	-0,93	-0,71	Reprovado
5	915	8,9	1,25	0,92	Aprovado
6	873	8,9	1,07	0,92	Aprovado
7	520	7,5	-0,46	-0,35	Reprovado
8	297	5,9	-1,43	-1,79	Reprovado
9	358	7,2	-1,17	-0,62	Reprovado
10	884	8,8	1,12	0,83	Aprovado
11	725	9,0	0,43	1,01	Aprovado
12	612	7,7	-0,06	-0,17	Reprovado

E pronto! Todos os dados não rotulados tiveram seus rótulos estimados pelo classificador do modelo de partículas.

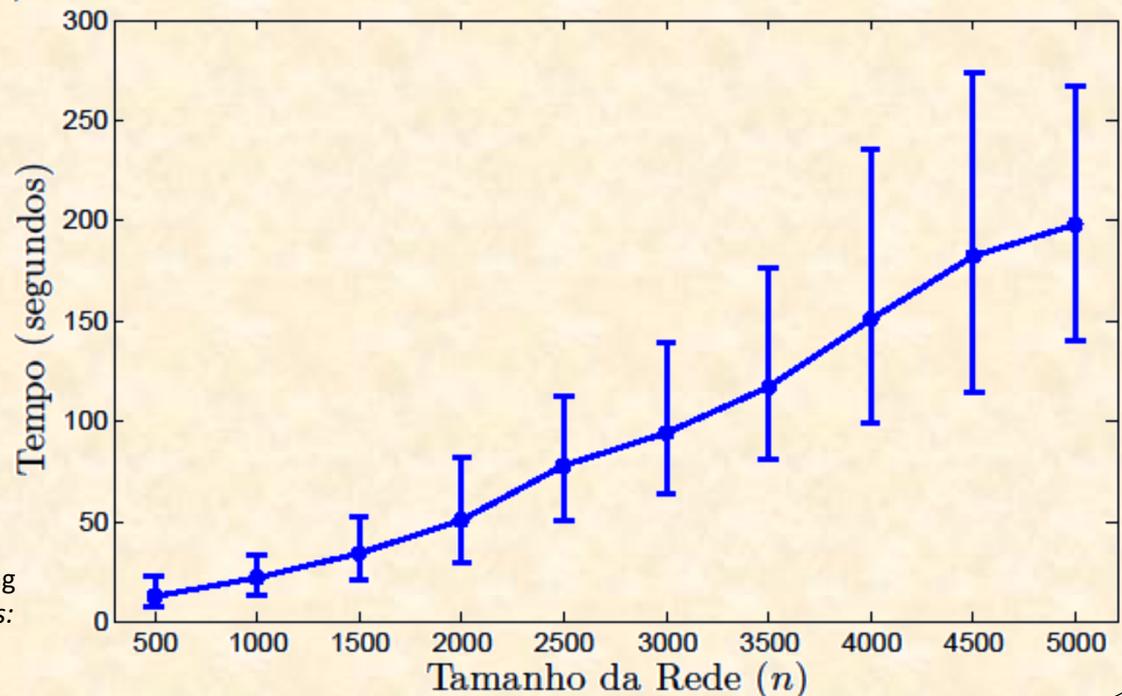


Análise de Complexidade

Análise de complexidade do método proposto em rede com média mistura: (a) Número de iterações e (b) tempo necessários para a convergência da média dos maiores níveis de domínio dos nós com tamanho de rede crescente

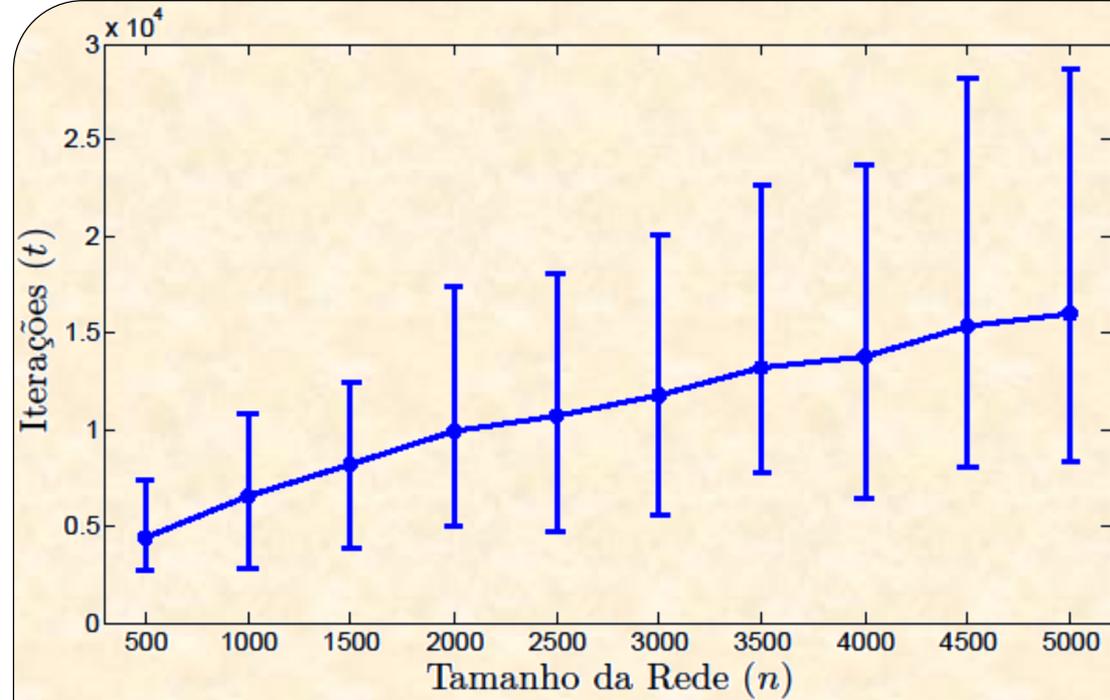


$$l = 50$$
$$\langle k \rangle = 25$$
$$z_{out} = 5$$
$$z_{out} / \langle k \rangle = 0,2$$



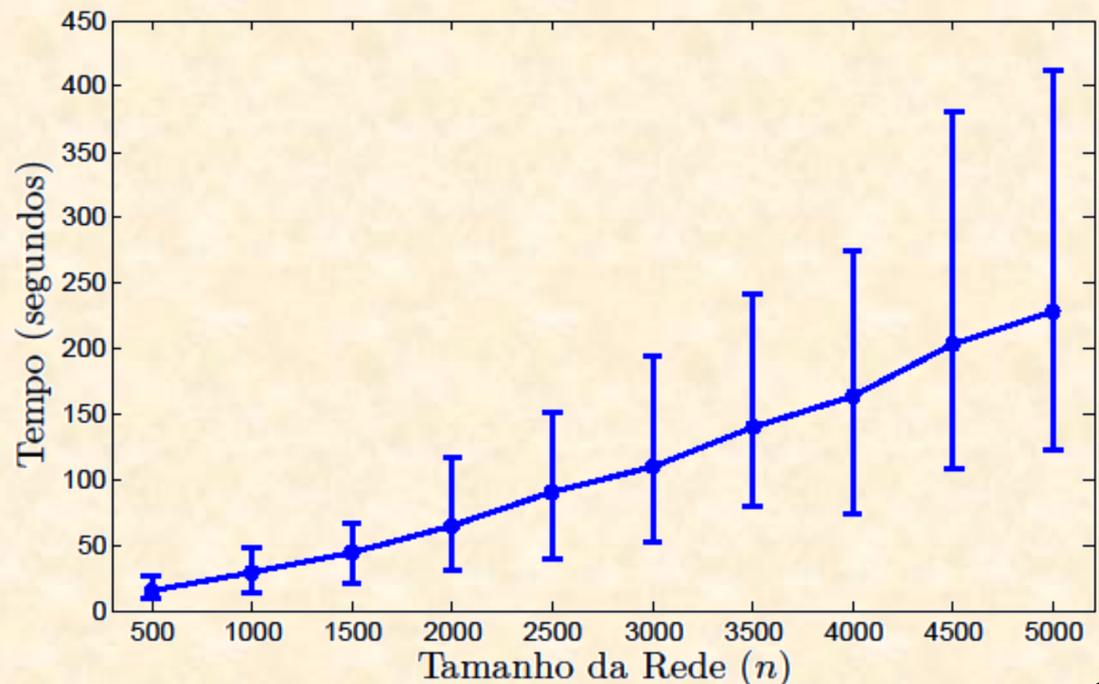
Análise de Complexidade

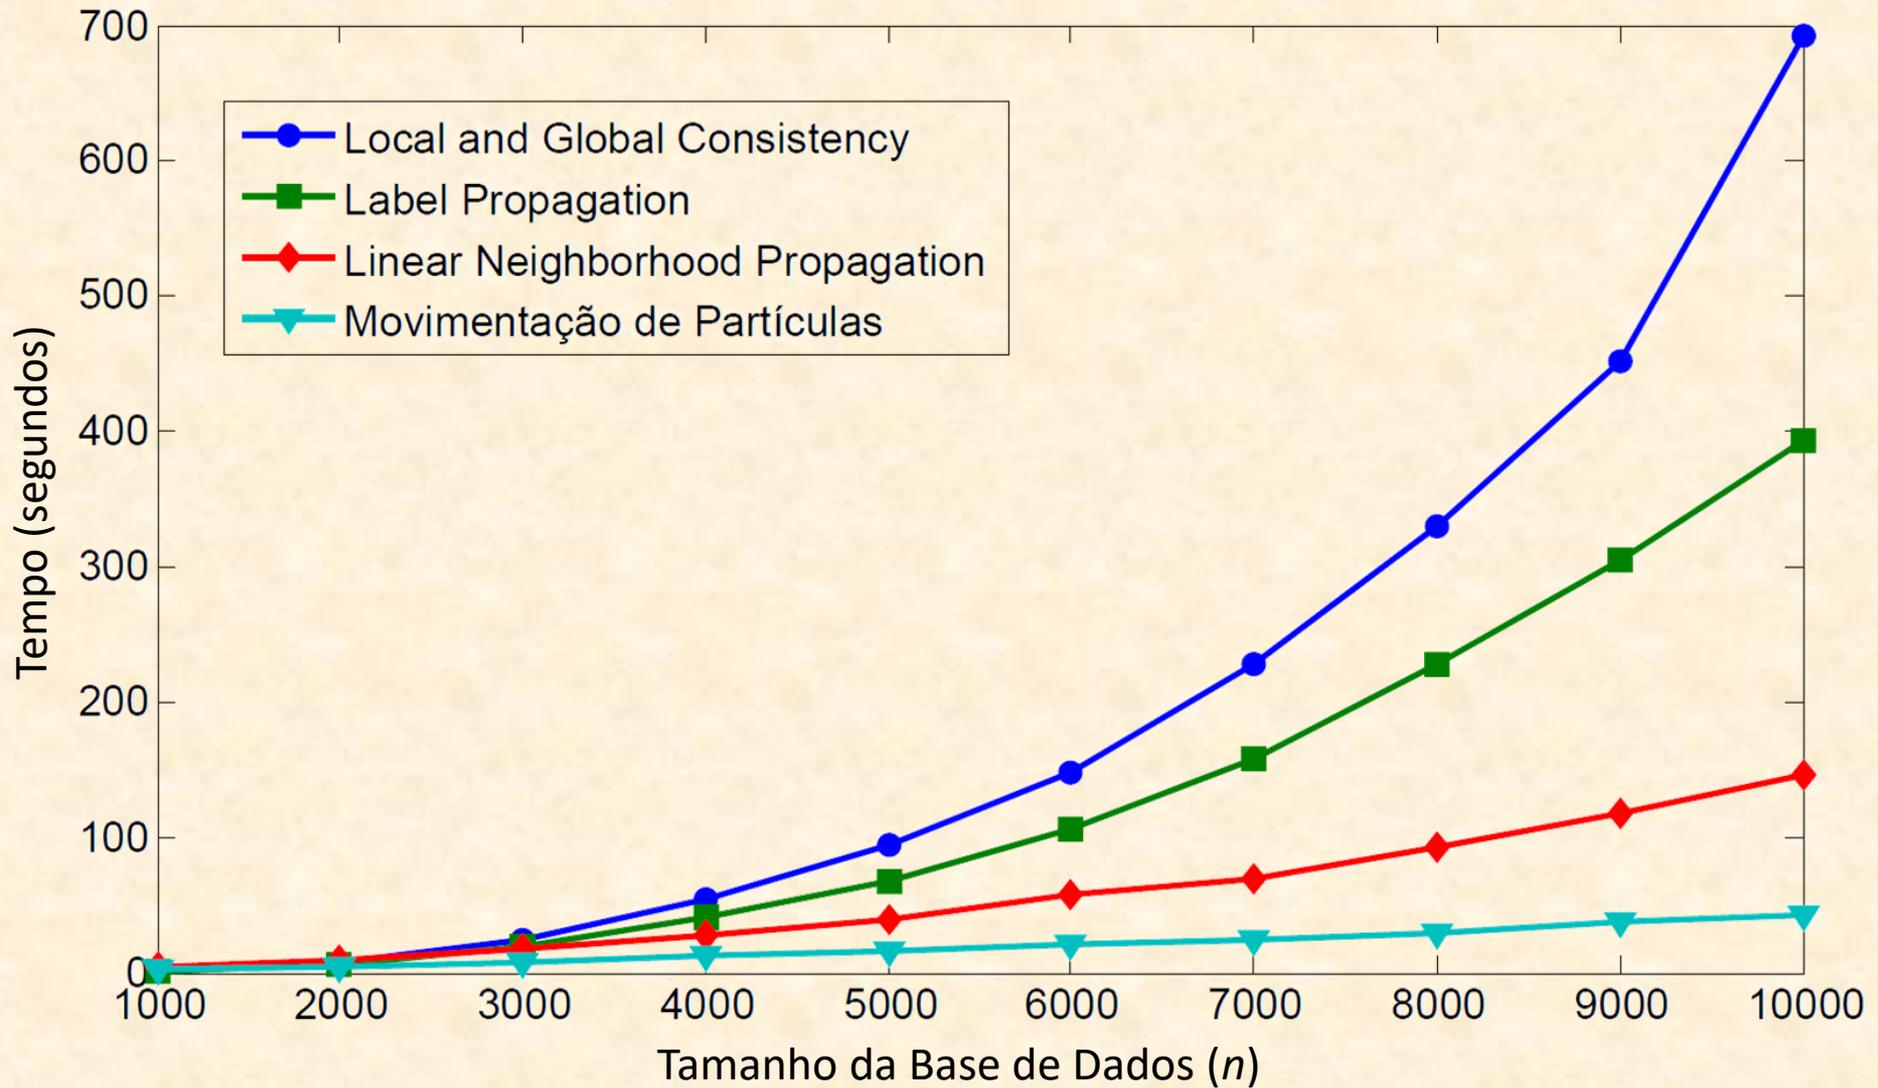
Análise de complexidade do método proposto em rede com alta mistura: (a) Número de iterações e (b) tempo necessários para a convergência da média dos maiores níveis de domínio dos nós com tamanho de rede crescente



$l = 50$
 $\langle k \rangle = 25$
 $z_{out} = 10$
 $z_{out} / \langle k \rangle = 0,4$

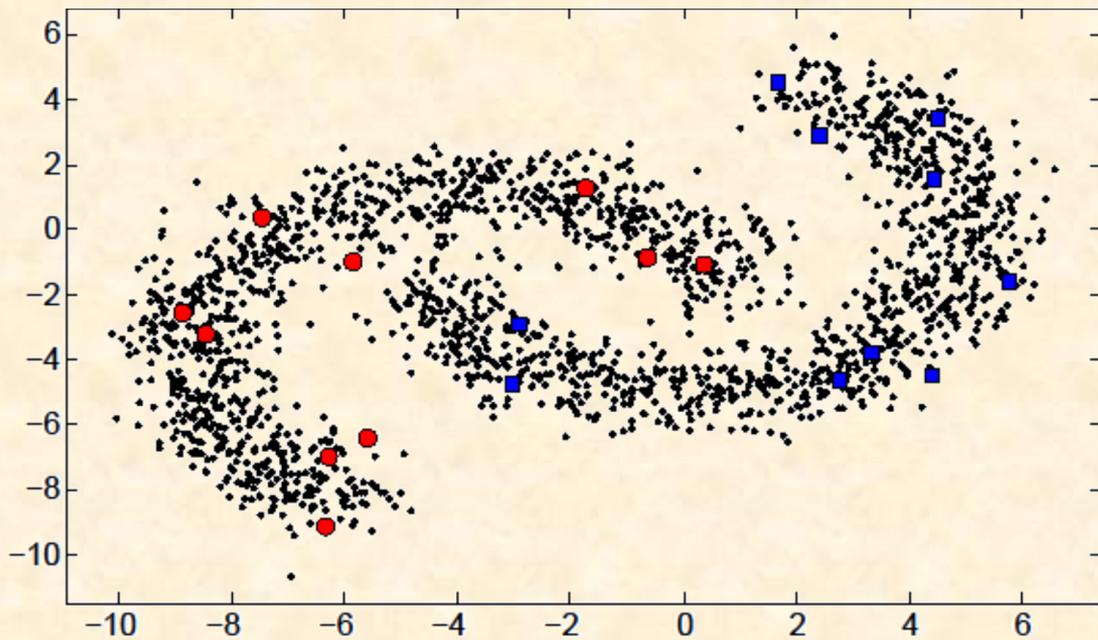
L. Danon, A. Díaz-Guilera, J. Duch, and A. Arenas, "Comparing Community Structure Identification," *J. Statistical Mechanics: Theory and Experiment*, vol. 9, p. P09008 (1-10), 2005.



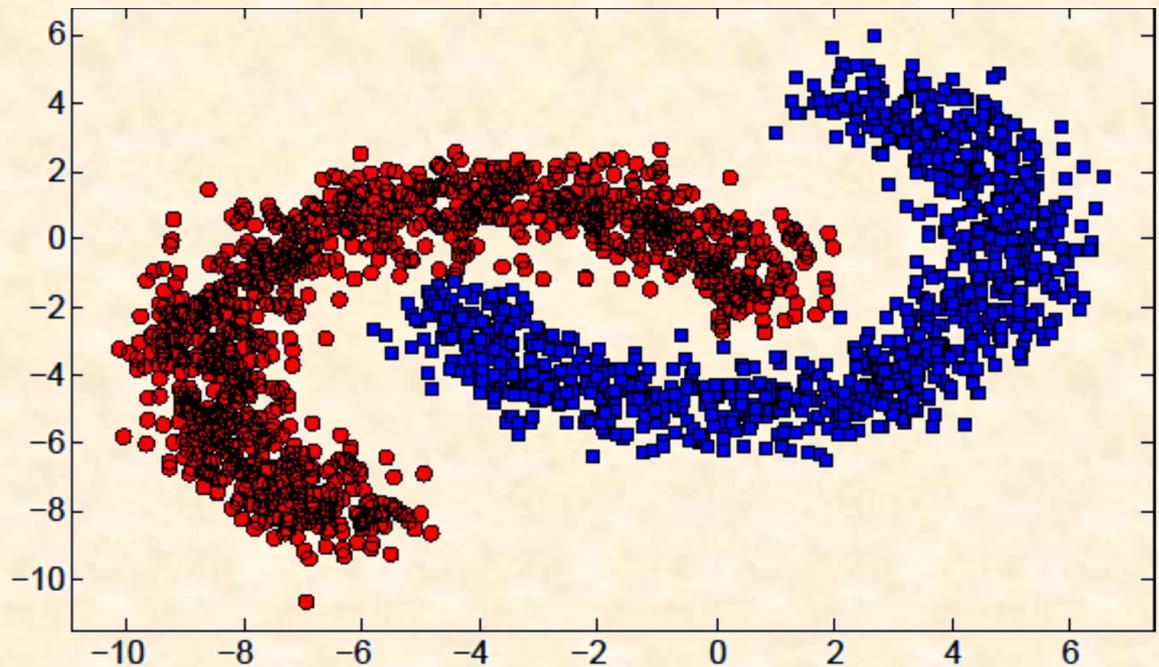


Tempo de execução de quatro métodos baseados em grafos, incluindo o método de competição e cooperação entre partículas, para classificar uma sequência de bases de dados artificiais com 4 classes com distribuição Gaussiana, com tamanhos crescentes.

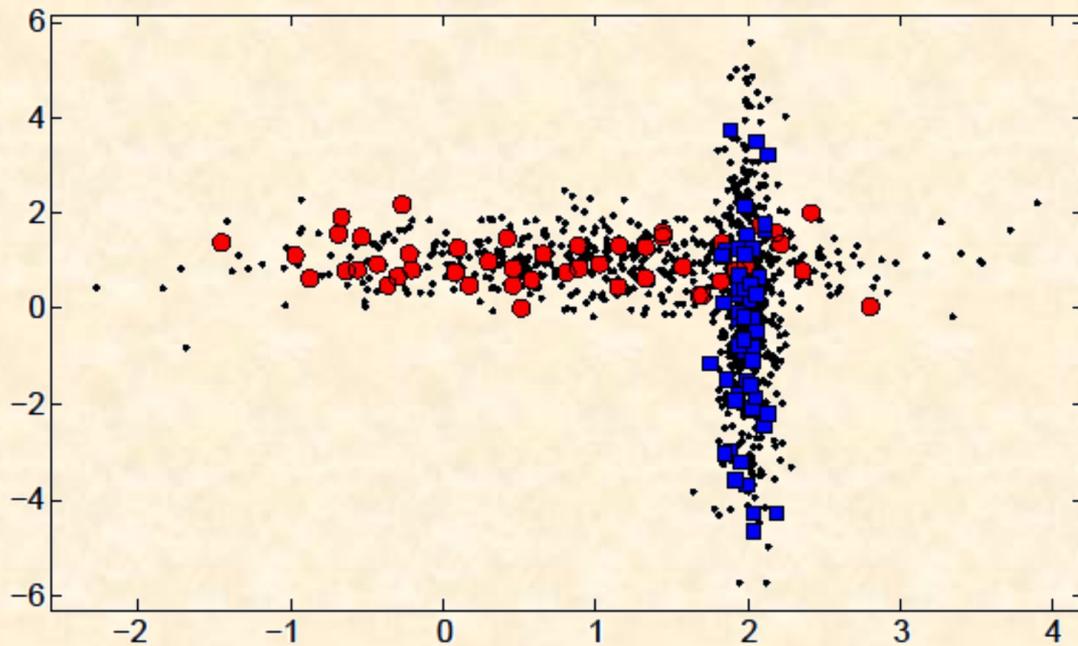
Desempenho de Classificação



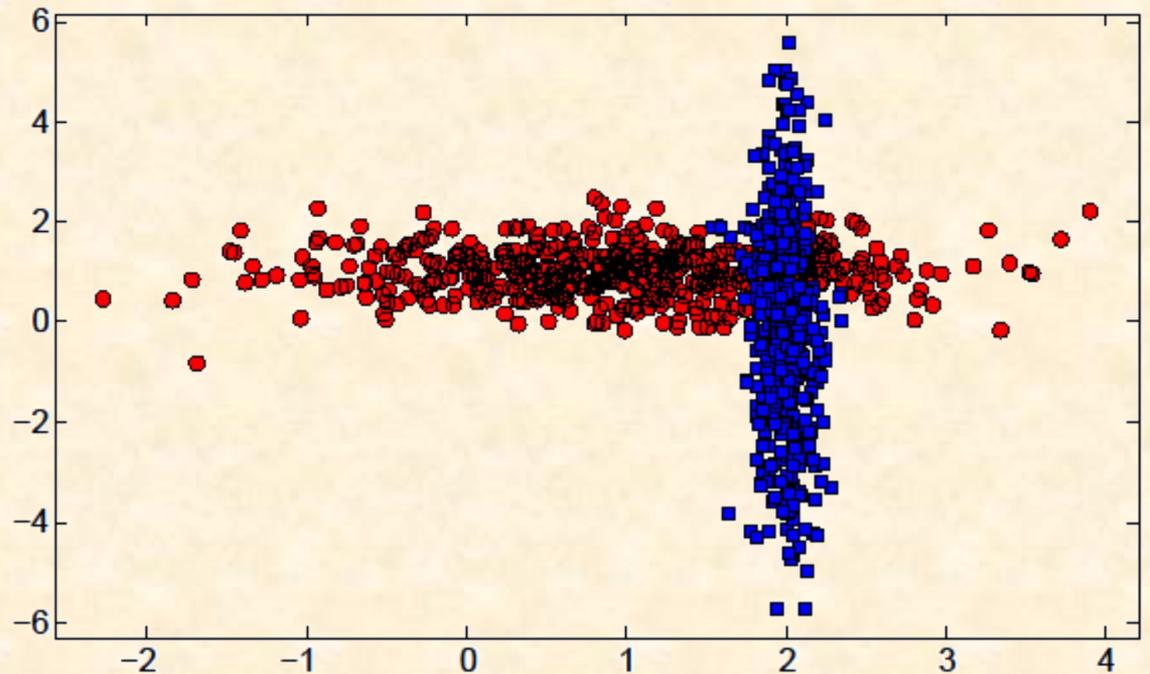
Classificação de base de
dados artificial com 2.000
amostras divididas
igualmente em duas
classes com forma de
banana



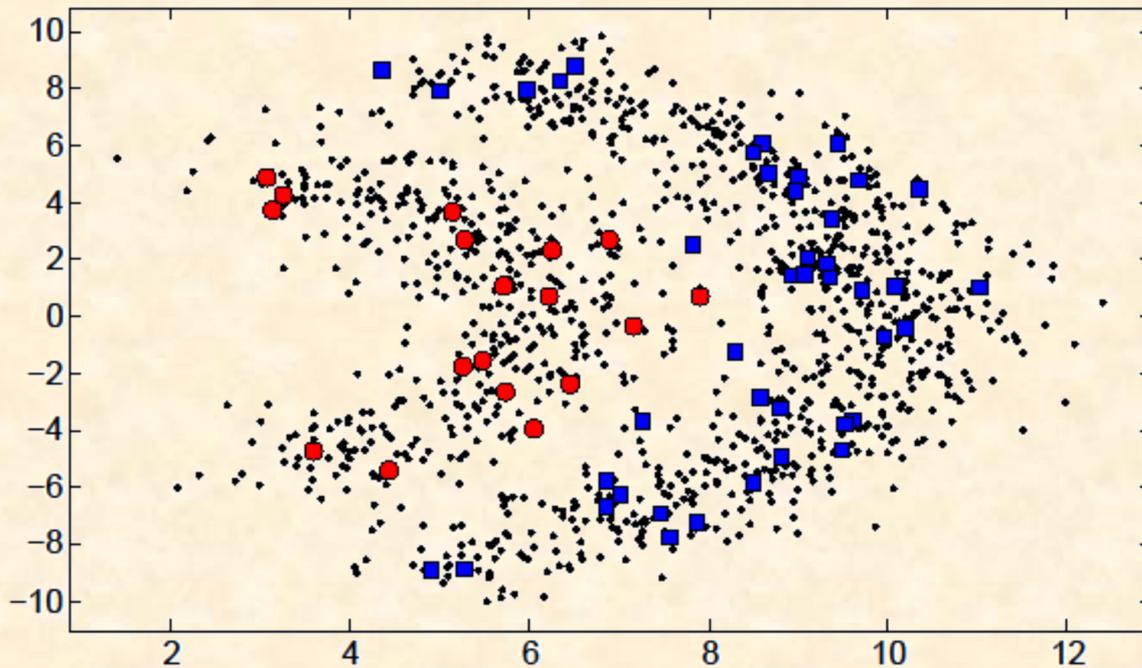
Desempenho de Classificação



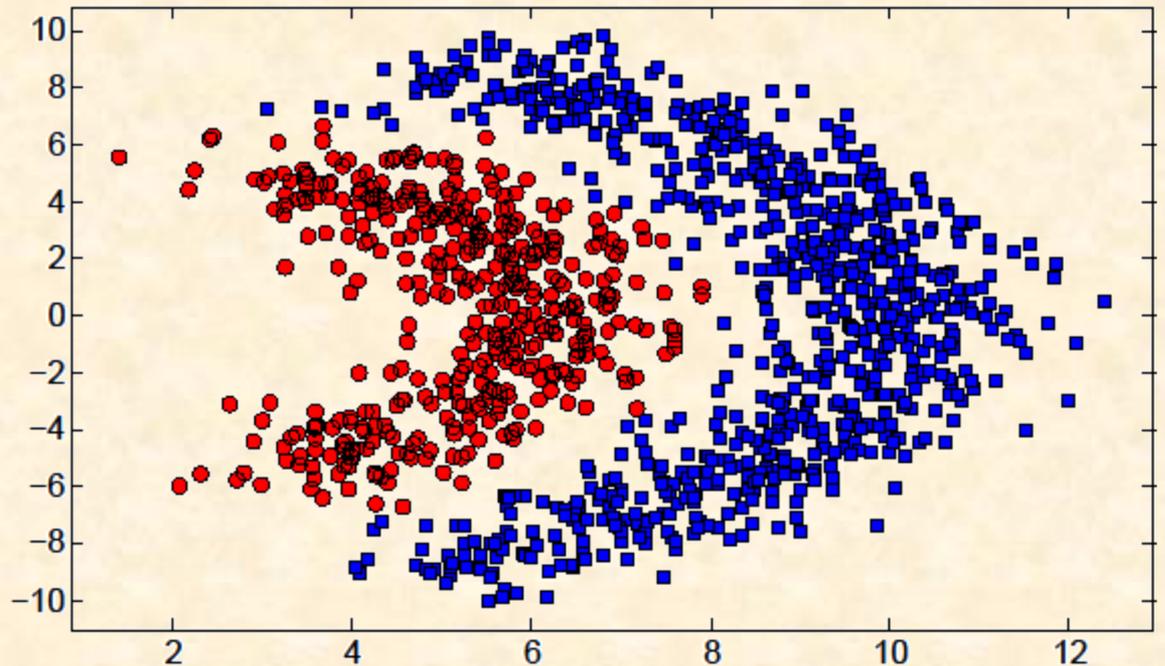
Classificação de base de dado artificial com 1.000 amostras divididas em duas classes Highleyman



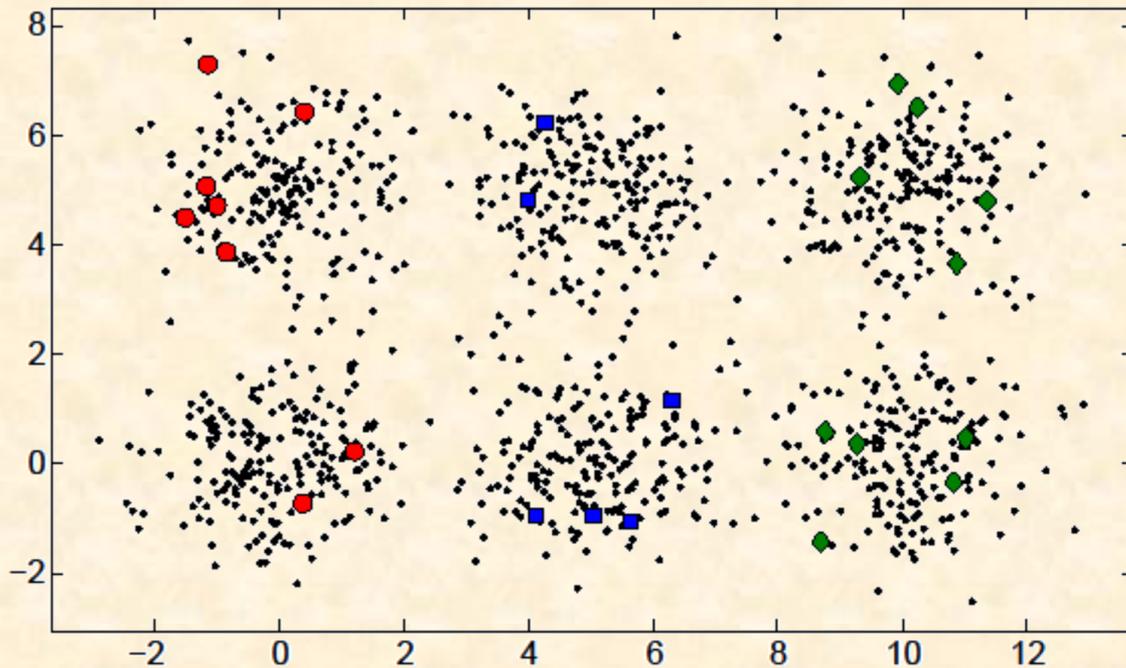
Desempenho de Classificação



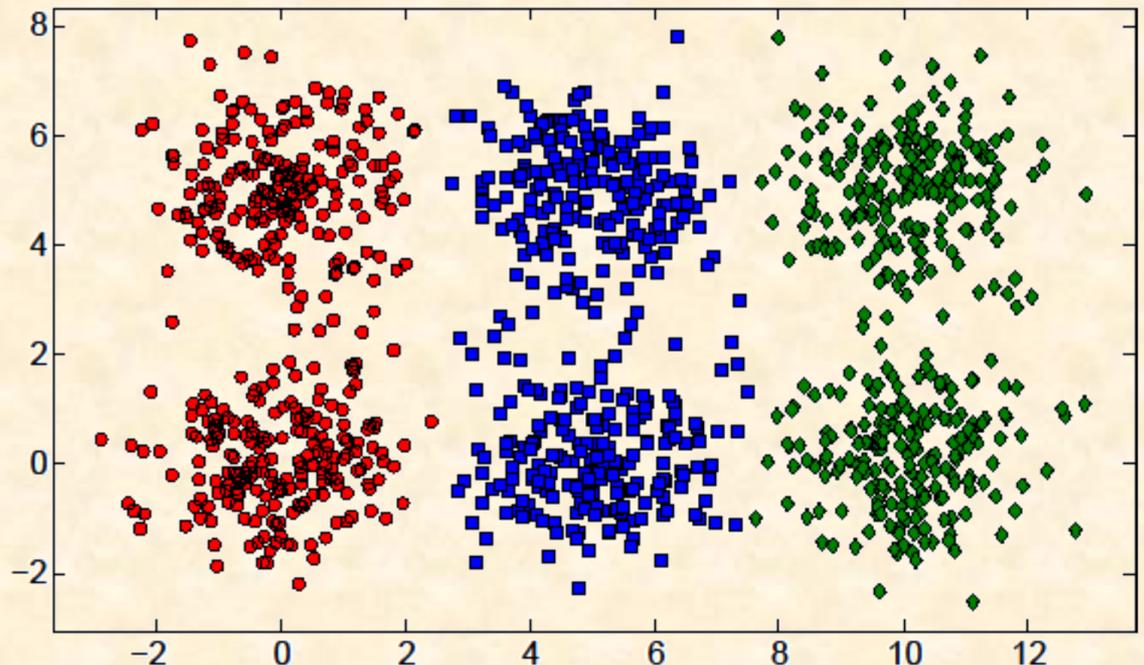
Classificação de base de dado artificial com 1.200 amostras divididas em duas classes Lithuanian, com 800 e 400 amostras respectivamente



Desempenho de Classificação



Classificação de base de
dado artificial com 1.200
amostras igualmente
divididas em três classes
com distribuição
Gaussiana.



	g241c	g241d	Digit1	USPS	COIL	BCI	Text
1-NN	43.93	42.45	3.89	5.81	17.35	48.67	30.11
SVM	23.11	24.64	5.53	9.75	22.93	34.31	26.45
MVU + 1-NN	43.01	38.20	2.83	6.50	28.71	47.89	32.83
LEM + 1-NN	40.28	37.49	6.12	7.64	23.27	44.83	30.77
QC + CMN	22.05	28.20	3.15	6.36	10.03	46.22	25.71
Discrete Reg.	43.65	41.65	2.77	4.68	9.61	47.67	24.00
TSVM	18.46	22.42	6.15	9.77	25.80	33.25	24.52
SGT	17.41	9.11	2.61	6.80	-	45.03	23.09
Cluster-Kernel	13.49	4.95	3.79	9.68	21.99	35.17	24.38
Data-Dep. Reg.	20.31	32.82	2.44	5.10	11.46	47.47	-
LDS	18.04	23.74	3.46	4.96	13.72	43.97	23.15
Laplacian RLS	24.36	26.46	2.92	4.68	11.92	31.36	23.57
CHM (normed)	24.82	25.67	3.79	7.65	-	36.03	-
LGC	41.64	40.08	2.72	3.68	45.55	43.50	46.83
LP	30.39	29.22	3.05	6.98	11.14	42.69	40.79
LNP	44.13	38.30	3.27	17.22	11.01	46.22	38.48
Proposed Method	24.20	23.93	2.65	4.65	14.85	44.38	25.03

	<i>g241c</i>	<i>g241d</i>	<i>Digit1</i>	<i>USPS</i>	<i>COIL</i>	<i>BCI</i>	<i>Text</i>	<i>Mean</i>	<i>Std. Dev.</i>
1-NN	16	16	14	7	9	17	10	12.7	3.72
SVM	7	6	15	15	11	3	9	9.4	4.42
MVU + 1-NN	14	13	6	9	14	16	12	12.0	3.30
LEM + 1-NN	12	12	16	12	12	10	11	12.1	1.86
QC + CMN	6	9	9	8	2	12	8	7.7	3.00
Discrete Reg.	15	15	5	3	1	15	4	8.3	5.68
TSVM	4	3	17	16	13	2	6	8.7	6.08
SGT	2	2	2	10	-	11	1	4.7	4.36
Cluster-Kernel	1	1	12	14	10	4	5	6.7	4.66
Data-Dep. Reg.	5	11	1	6	5	14	-	7.0	4.59
LDS	3	4	11	5	7	8	2	5.7	2.92
Laplacian RLS	9	8	7	3	6	1	3	5.3	2.51
CHM (normed)	10	7	12	13	-	5	-	9.4	3.35
LGC	13	15	4	1	15	7	15	10.0	5.77
LP	11	10	8	11	4	6	14	9.1	3.29
LNP	17	14	10	17	3	12	13	12.3	4.36
Proposed Method	8	5	3	2	8	9	7	6.0	2.56

Ranking dos Métodos de Aprendizado Semi-Supervisionado com 100 pontos de dados rotulados

	g241c	g241d	Digit1	USPS	COIL	BCI	Text
1-NN	47.88	46.72	13.65	16.66	63.36	49.00	38.12
SVM	47.32	46.66	30.60	20.03	68.36	49.85	45.37
MVU + 1-NN	47.15	45.56	14.42	23.34	62.62	47.95	45.32
LEM + 1-NN	44.05	43.22	23.47	19.82	65.91	48.74	39.44
QC + CMN	39.96	46.55	9.80	13.61	59.63	50.36	40.79
Discrete Reg.	49.59	49.05	12.64	16.07	63.38	49.51	40.37
TSVM	24.71	50.08	17.77	25.20	67.50	49.15	31.21
SGT	22.76	18.64	8.92	25.36	-	49.59	29.02
Cluster-Kernel	48.28	42.05	18.73	19.41	67.32	48.31	42.72
Data-Dep. Reg.	41.25	45.89	12.49	17.96	63.65	50.21	-
LDS	28.85	50.63	15.63	17.57	61.90	49.27	27.15
Laplacian RLS	43.95	45.68	5.44	18.99	54.54	48.97	33.68
CHM (normed)	39.03	43.01	14.86	20.53	-	46.90	-
LGC	45.82	44.09	9.89	9.03	63.45	47.09	45.50
LP	42.61	41.93	11.31	14.83	55.82	46.37	49.53
LNP	47.82	46.24	8.58	17.87	55.50	47.65	41.06
Proposed Method	37.57	43.94	9.94	17.44	58.65	47.66	31.15

	<i>g241c</i>	<i>g241d</i>	<i>Digit1</i>	<i>USPS</i>	<i>COIL</i>	<i>BCI</i>	<i>Text</i>	<i>Mean</i>	<i>Std. Dev.</i>
1-NN	15	14	10	5	8	10	6	9.7	2.99
SVM	13	13	17	13	15	15	13	14.1	1.49
MVU + 1-NN	12	8	11	15	7	6	12	10.1	3.13
LEM + 1-NN	10	5	16	12	12	8	7	10.0	3.70
QC + CMN	6	12	4	2	5	17	9	7.9	5.15
Discrete Reg.	17	15	9	4	9	13	8	10.7	3.57
TSVM	2	16	13	16	14	11	4	10.9	4.15
SGT	1	1	3	17	-	14	2	6.3	6.73
Cluster-Kernel	16	3	15	11	13	7	10	10.7	3.95
Data-Dep. Reg.	7	10	8	9	11	16	-	10.2	2.80
LDS	3	17	14	7	6	12	1	8.6	5.39
Laplacian RLS	9	9	1	10	1	9	5	6.3	3.76
CHM (normed)	5	4	12	14	-	2	-	7.4	5.11
LGC	11	7	5	1	10	3	14	7.3	4.35
LP	8	2	7	3	3	1	15	5.6	4.78
LNP	14	11	2	8	2	4	11	7.4	3.88
Proposed Method	4	6	6	6	4	5	3	4.9	1.16

Ranking dos Métodos de Aprendizado Semi-Supervisionado com 10 pontos de dados rotulados

Erros de Classificação e Tempos de Execução em Grandes Bases de Dados

	LGC		LP		LNP		Prop. Method	
	Error	Time	Error	Time	Error	Time	Error	Time
USPS - 10%	3.73	457	7.27	154	12.80	105	4.37	69
USPS - 5%	4.72	456	9.77	243	5.99	107	5.13	76
USPS - 1%	9.38	461	23.77	579	22.54	120	9.29	103
COIL - 10%	7.64	445	8.14	54	11.09	73	5.79	23
COIL - 5%	7.48	443	7.92	59	11.38	68	5.84	28
COIL - 1%	7.36	472	7.16	83	8.03	65	5.94	33
Letter - 10%	-	-	10.94	2232	24.04	1010	11.74	484
Letter - 5%	-	-	18.99	1901	33.89	982	16.86	497
Letter - 1%	-	-	46.94	5495	54.28	1274	39.76	522

Erros de classificação (%) e tempos de execução (segundos) de quatro métodos baseados em grafos aplicados em bases de dados grandes

Extensões do Modelo de Partículas

Detecção de Comunidades Sobrepostas

Aprendizado Semi-Supervisionado com Dados Imperfeitos

Classificação Semi-Supervisionada de Fluxos de Dados

Aprendizado Ativo e Semi-Supervisionado

Segmentação de Imagens

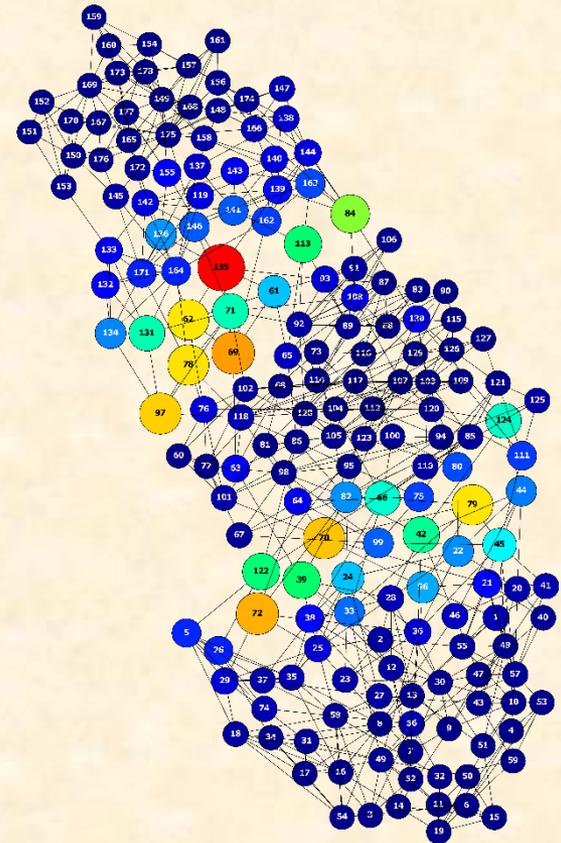
Extensões do Modelo de Partículas

- O modelo de Competição e Cooperação entre Partículas já foi estendido para realizar diversos tipos de tarefas de aprendizado de máquina
 - **Detecção de Comunidades Sobrepostas**
 - **Aprendizado Semi-Supervisionado com Dados Imperfeitos**
 - Classificação Semi-Supervisionada de Fluxos de Dados
 - Aprendizado Ativo e Semi-Supervisionado
 - **Segmentação de Imagens**

Detecção de Comunidades Sobrepostas

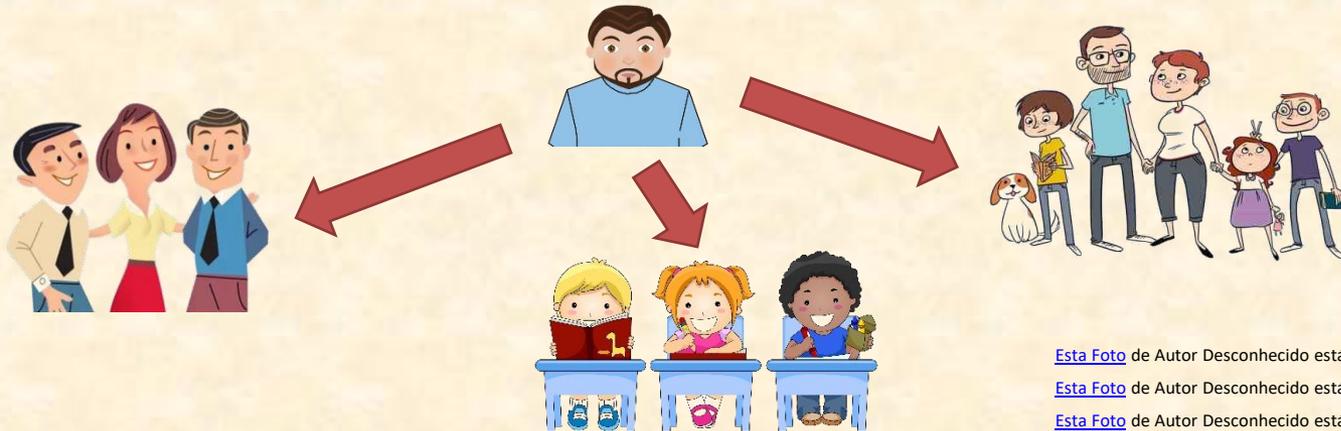
Breve, Fabricio ; ZHAO, Liang . **Fuzzy community structure detection by particle competition and cooperation**. *Soft Computing* (Berlin. Print), v. 17, p. 659-673, 2013.
<http://dx.doi.org/10.1007/s00500-012-0924-3>

BREVE, Fabricio Aparecido ; ZHAO, Liang ; QUILES, Marcos Gonçalves ; PEDRYCZ, Witold ; LIU, Jimming . **Particle Competition and Cooperation for Uncovering Network Overlap Community Structure**. In: *The 8th International Symposium on Neural Networks (ISNN 2011)*, 2011, Guilin, China. Lecture Notes in Computer Science. Berlin Heidelberg: Springer-Verlag, 2011. v.6677. p.426 – 433.
http://dx.doi.org/10.1007/978-3-642-21111-9_48



Detecção de Comunidades Sobrepostas

- Em problemas de classificação, nem sempre os elementos pertencem a um único grupo.
- Há casos em que elementos pertencem a múltiplas comunidades.
 - Exemplo: Redes Sociais
 - Múltiplos Grupos: família, colegas de trabalho, colegas de escola
- A maioria dos métodos não consegue detectar tal estrutura de sobreposição.



Modelo de Partículas aplicado à Detecção de Comunidades Sobrepostas

- Esta extensão oferece saídas contínuas através de um **nível de dominância acumulado**
 - Quantifica a dominância de cada time de partículas sobre os nós ao longo de toda a execução do algoritmo.
 - O nível de dominância acumulado inicia em zero para todas as classes e é aumentado somente quando o movimento aleatório é selecionado, na classe correspondente à partícula.
 - Nunca diminui.

$$v_i^{\lambda_\ell}(t + 1) = v_i^{\lambda_\ell}(t) + \rho_j^\omega(t)$$

Modelo de Partículas aplicado à Detecção de Comunidades Sobrepostas

- Ao final das iterações, o grau de pertinência de um elemento à cada classe é calculado.

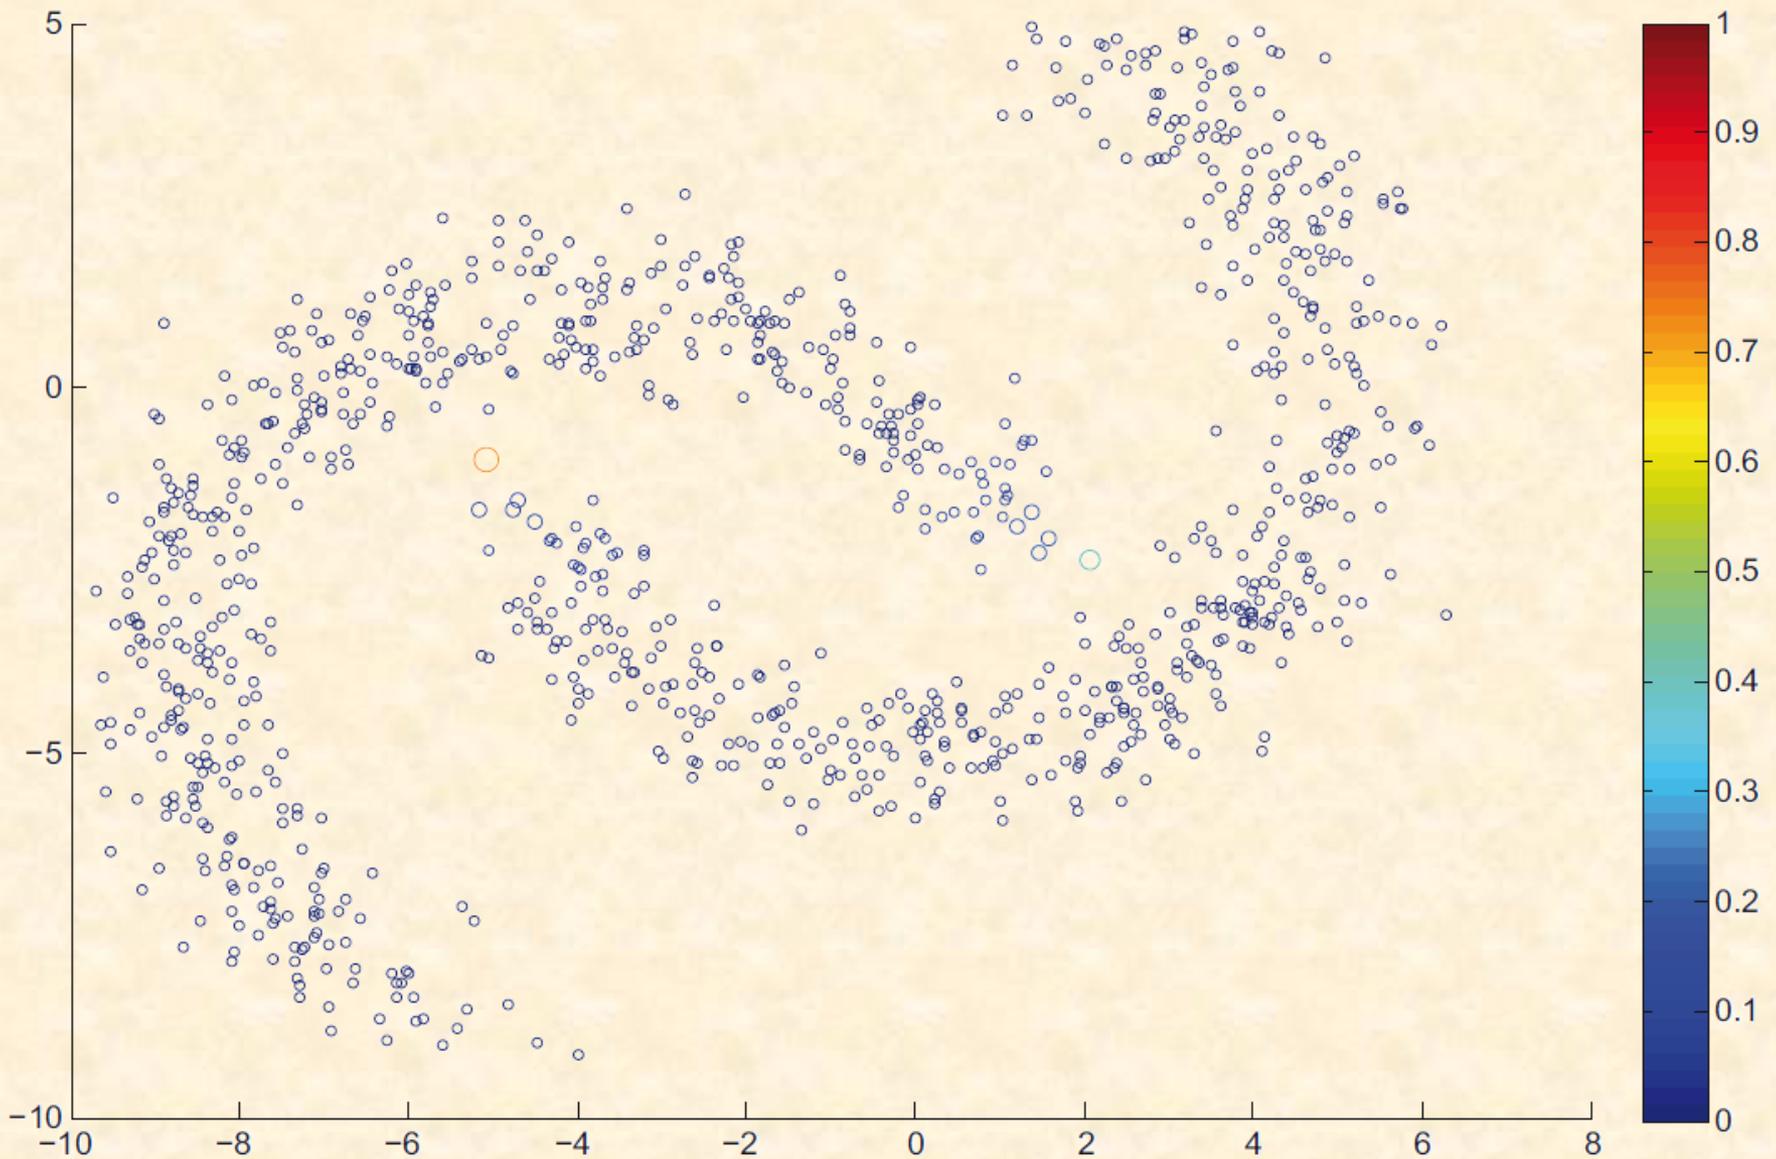
$$f_i^\ell = \frac{v_i^{\lambda_\ell}(\infty)}{\sum_{q=1}^c v_i^{\lambda_q}(\infty)}$$

- Um nível de sobreposição também pode ser calculado para cada elemento.

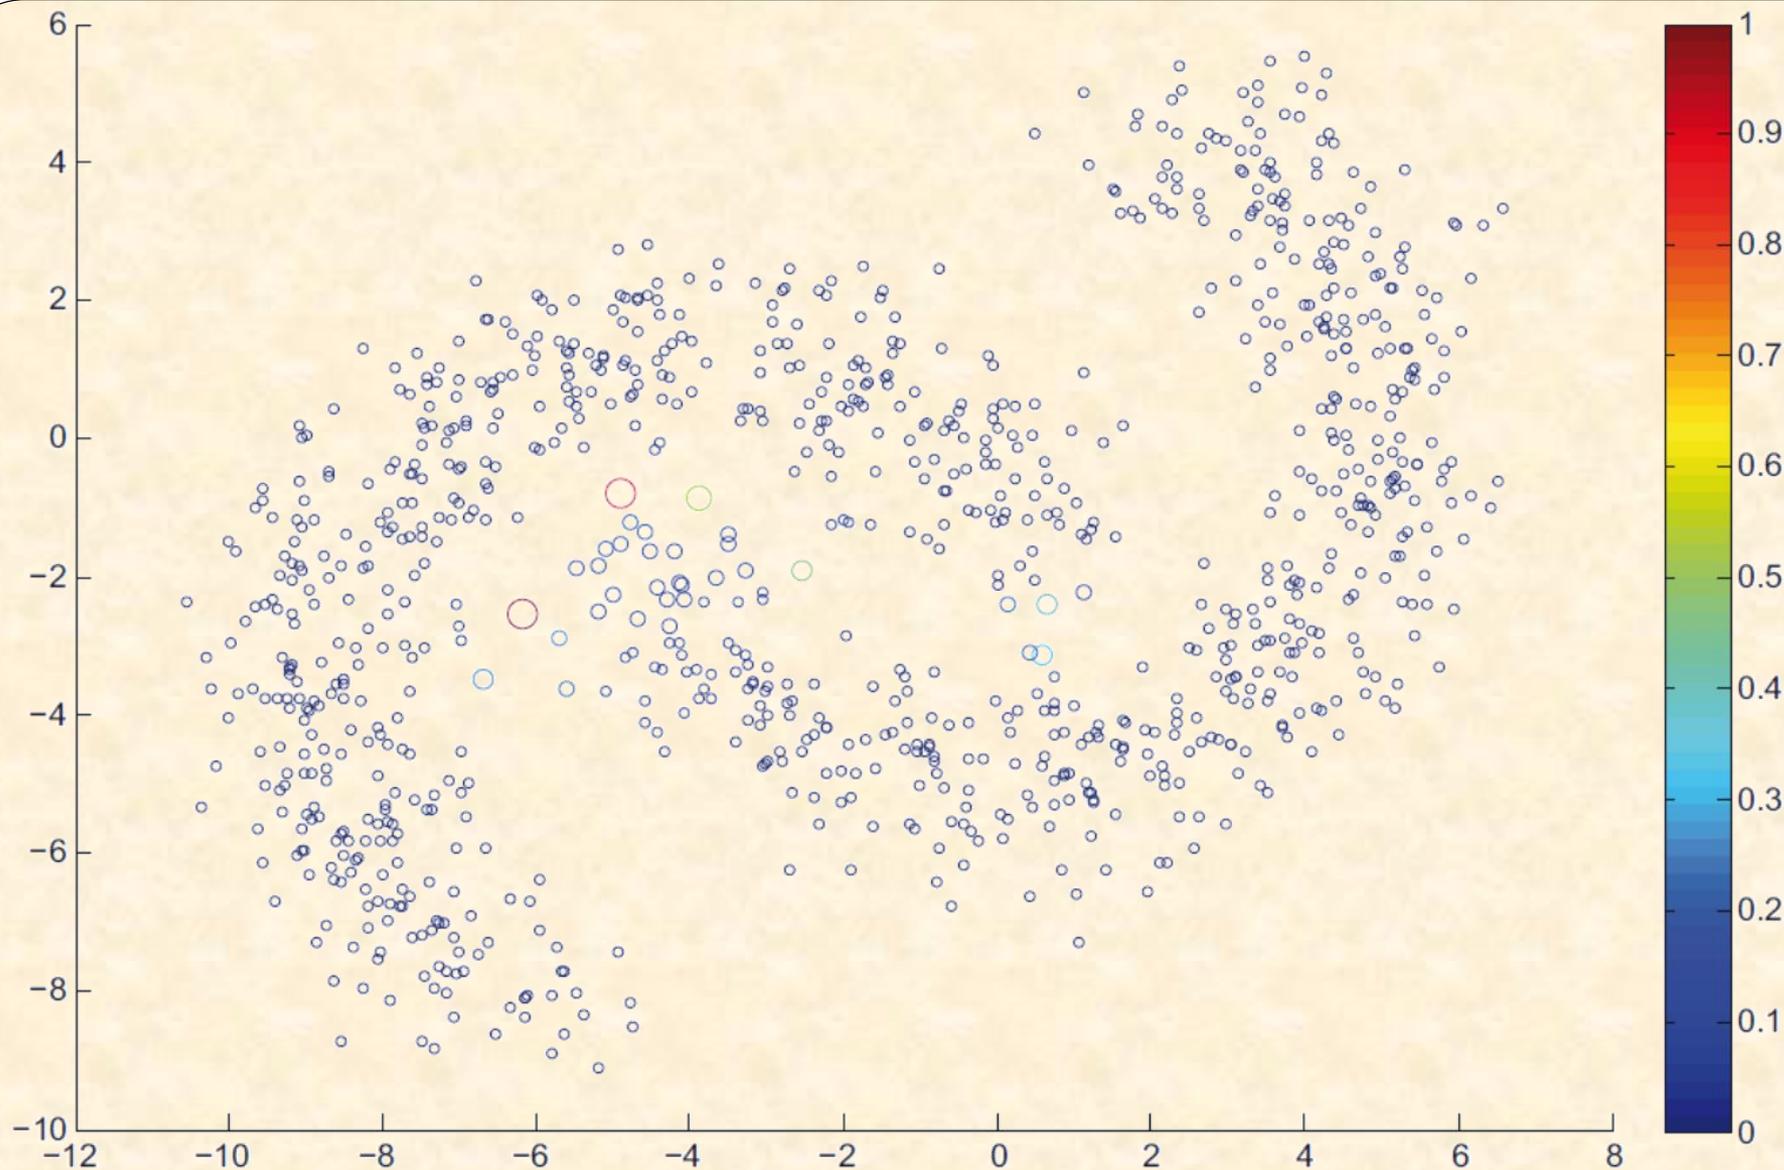
$$O_i = \frac{f_i^{\ell^{**}}}{f_i^{\ell^*}}$$

$f_i^{\ell^*}$ é o grau de pertinência da classe de maior pertinência

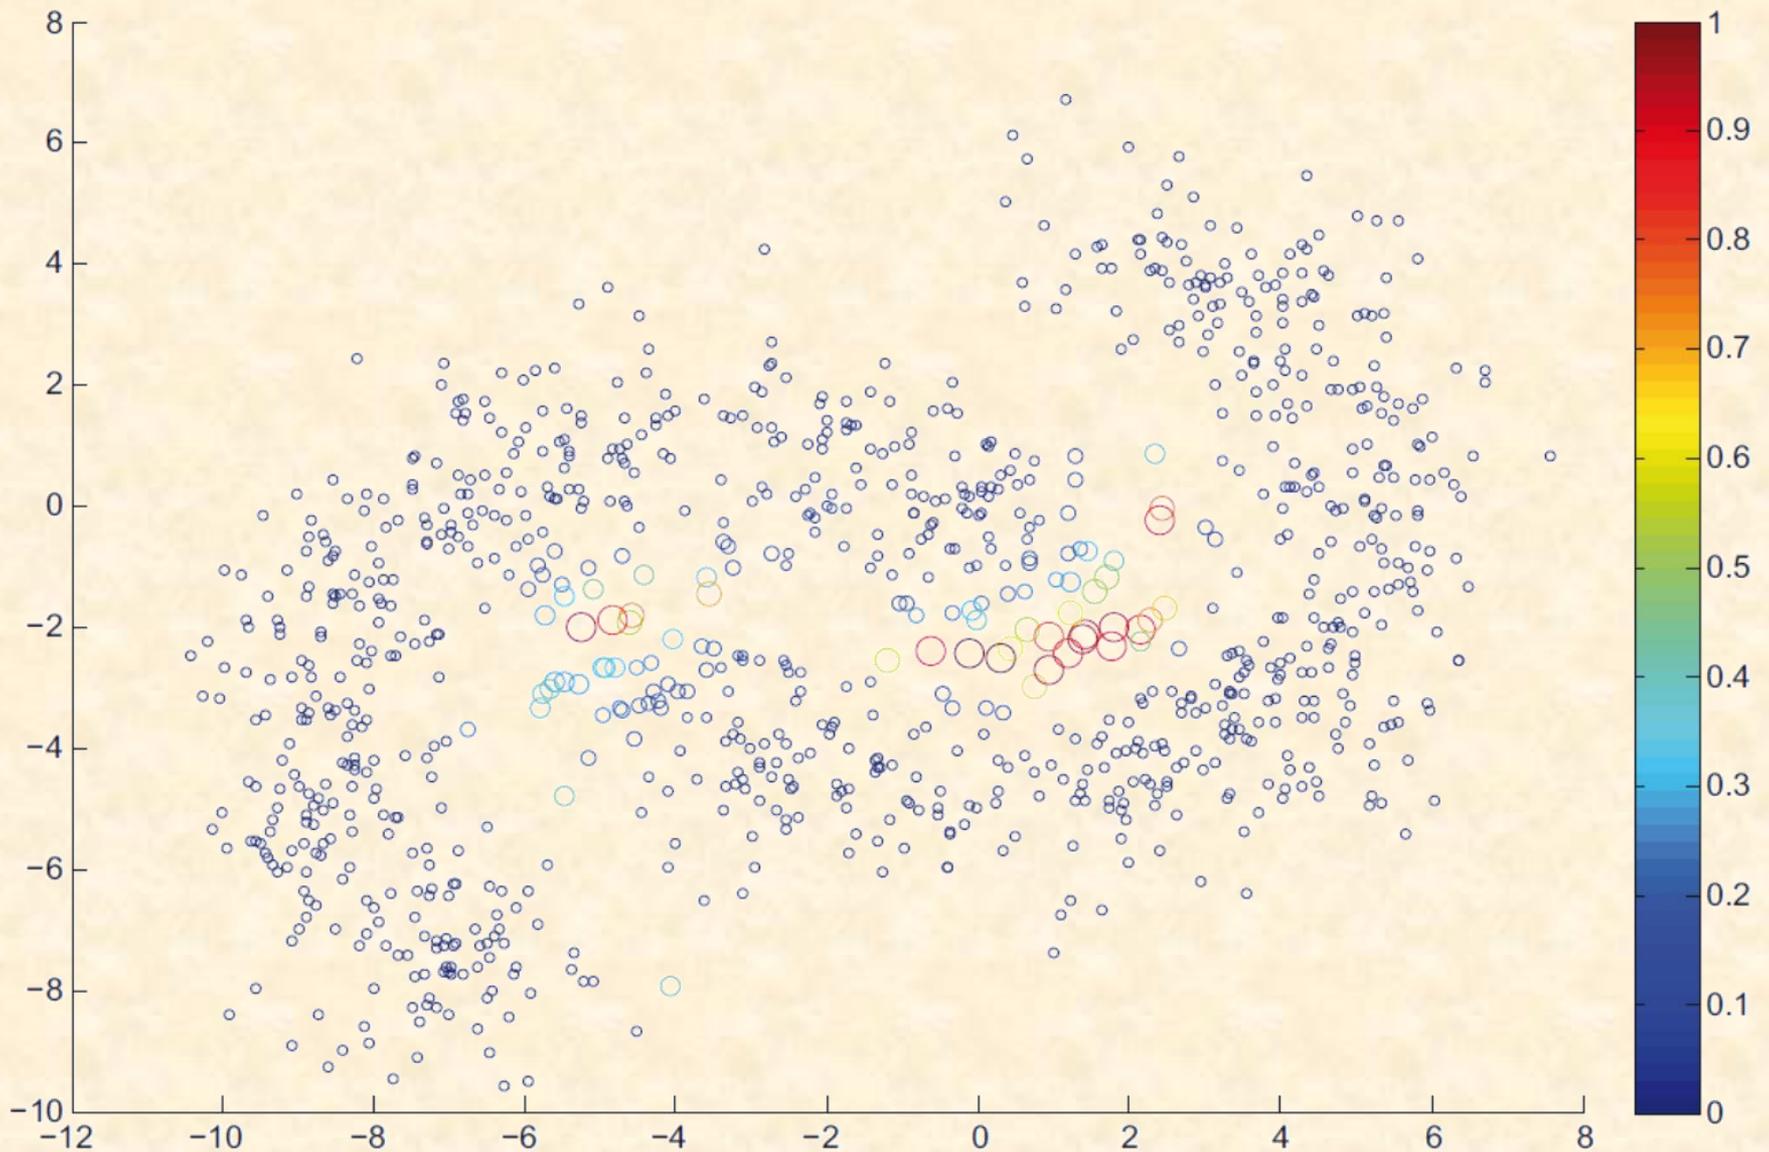
$f_i^{\ell^{**}}$ é o grau de pertinência da segunda classe de maior pertinência



Classificação nebulosa de classes em forma de banana geradas com diferentes parâmetros de variância: **(a)** $s = 0.6$ **(b)** $s = 0.8$ **(c)** $s = 1.0$. Tamanho e cor dos nós representam seu respectivo índice de sobreposição.



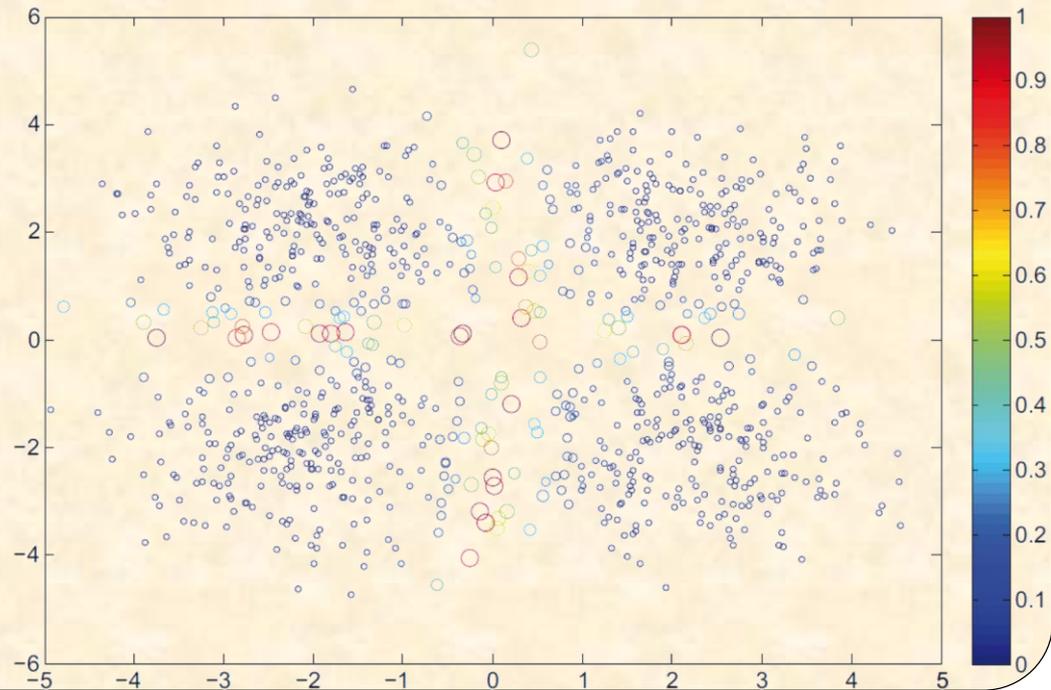
Classificação nebulosa de classes em forma de banana geradas com diferentes parâmetros de variância: (a) $s = 0.6$ (b) $s = 0.8$ (c) $s = 1.0$. Tamanho e cor dos nós representam seu respectivo índice de sobreposição.



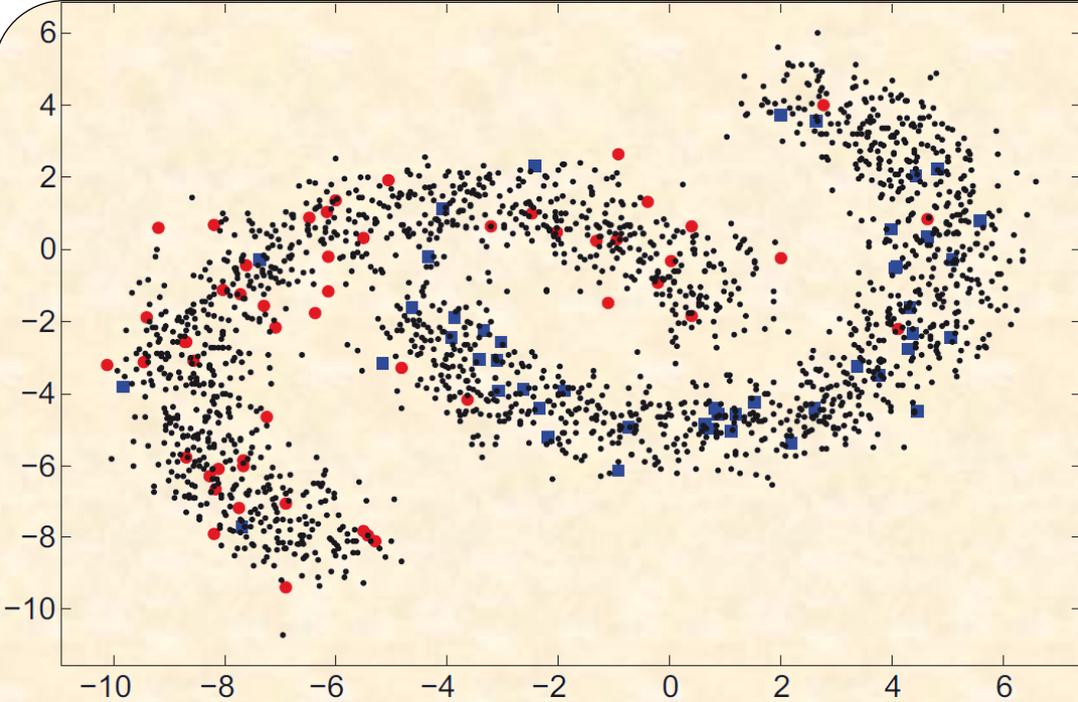
Classificação nebulosa de classes em forma de banana geradas com diferentes parâmetros de variância: (a) $s = 0.6$ (b) $s = 0.8$ (c) $s = 1.0$. Tamanho e cor dos nós representam seu respectivo índice de sobreposição.

Desempenho de Classificação Nebulosa

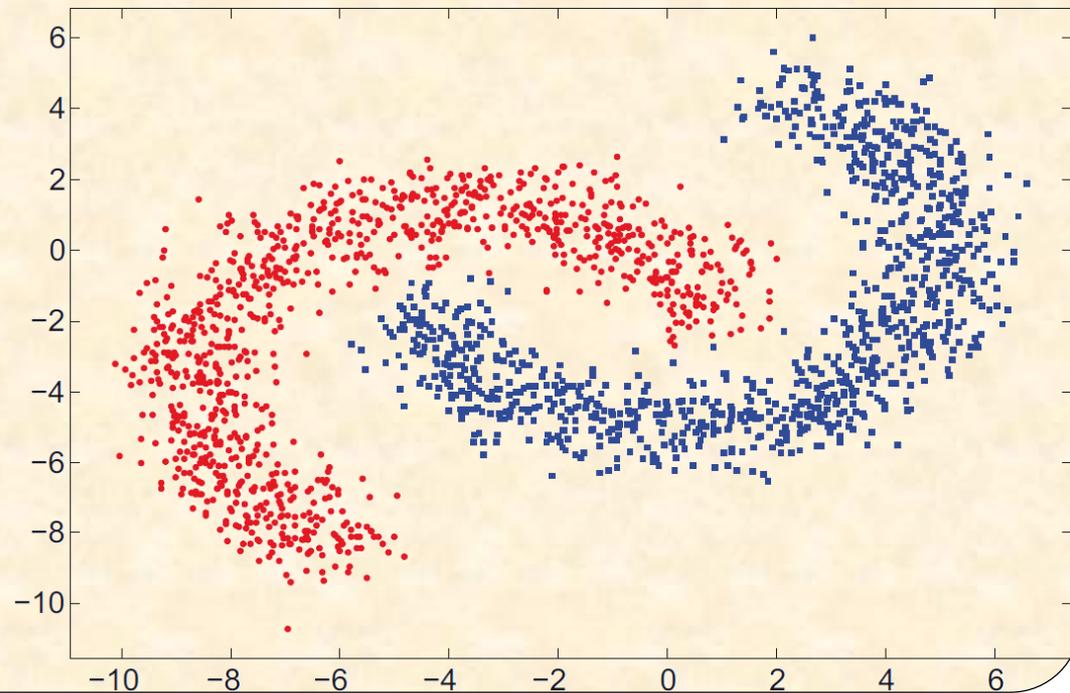
Classificação de dados com distribuição Gaussiana. (a) base de dados com 1.000 elementos divididos em quatro classes, 20 amostras são rotuladas, 5 de cada classe (quadrados, triângulos, losangos, e estrelas). (b) tamanhos e cores dos nós representam o índice de sobreposição calculado pelo método de partículas.



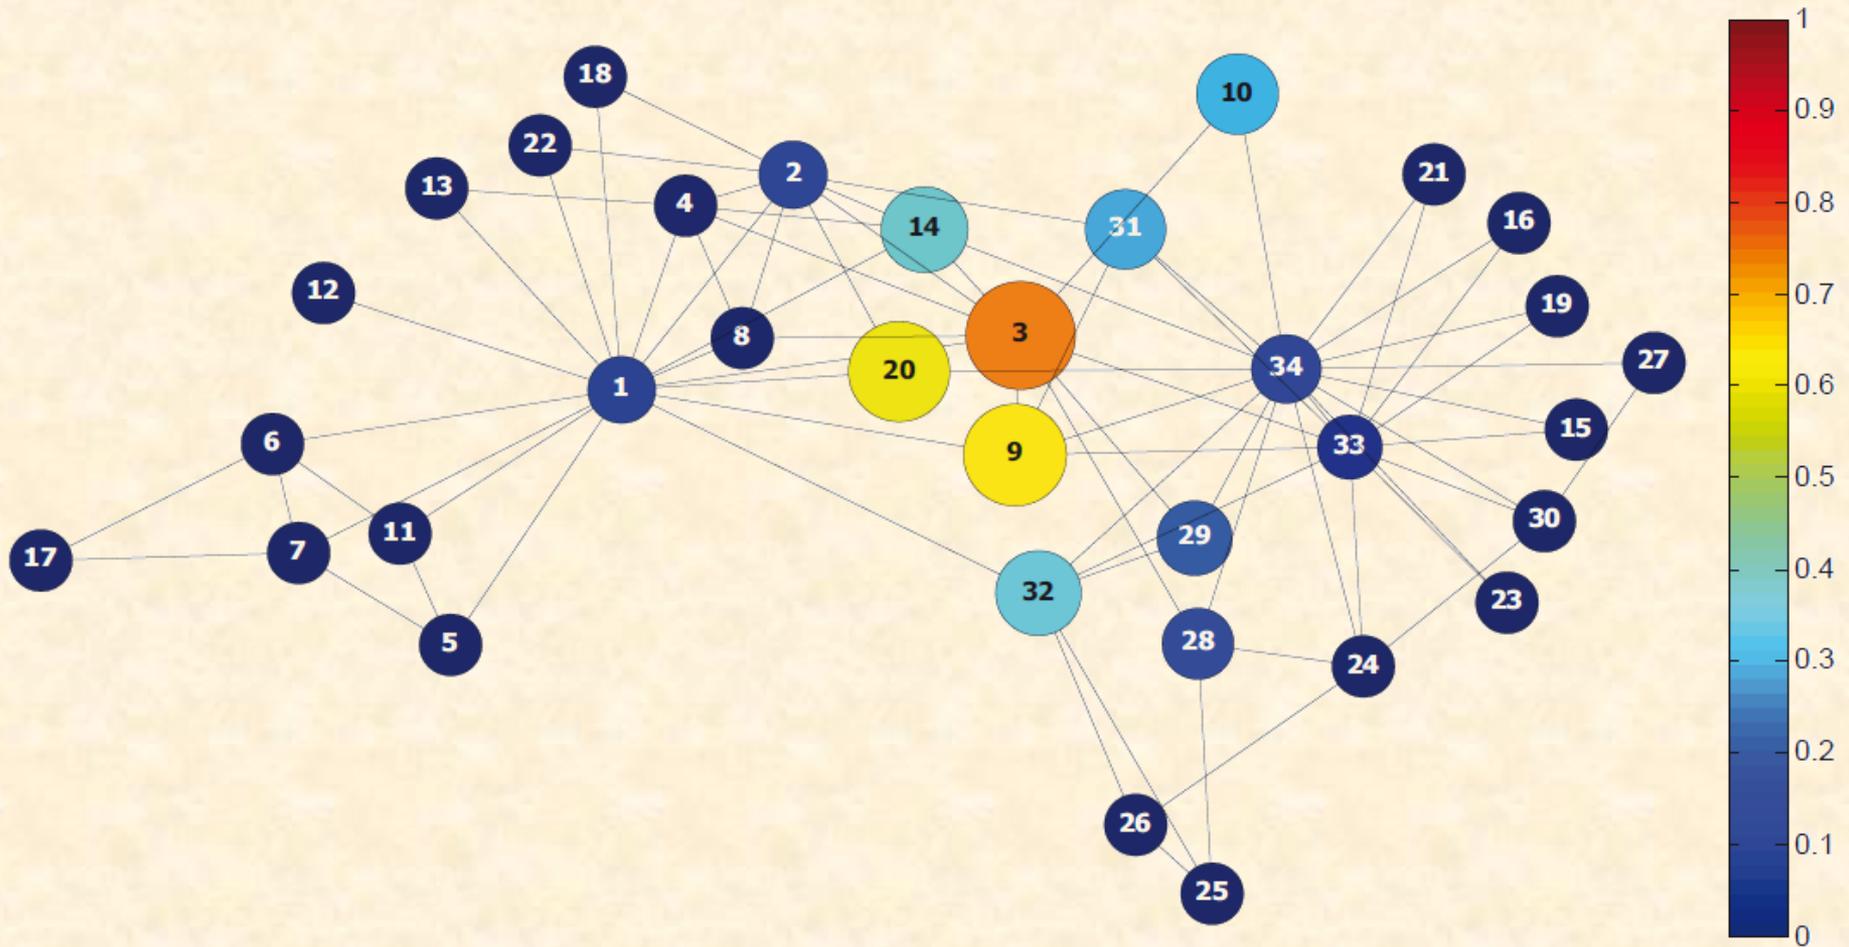
Desempenho de Classificação com presença de *outliers*



Classificação de base de dados com alguns *outliers*: (a) base de dados artificiais com alguns nós rotulados erroneamente (b) classificação pelo método proposto.



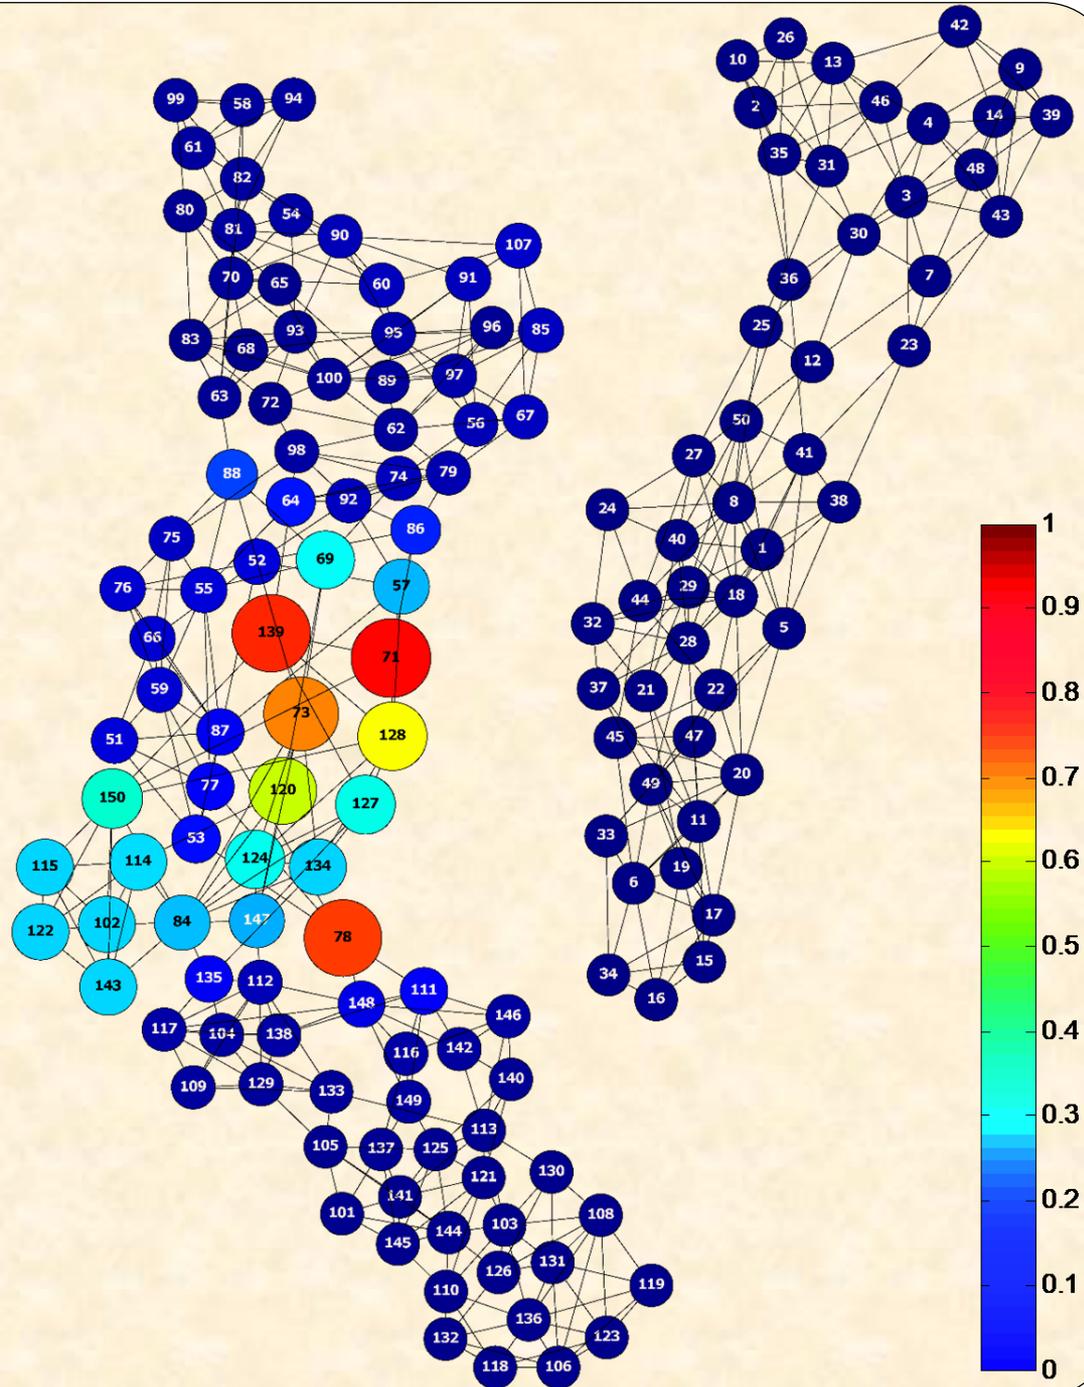
Classificação Nebulosa em Bases de Dados Reais



A Rede do Clube de Caratê. Tamanhos e cores dos nós representam o respectivo grau de sobreposição detectado pelo método proposto.

Classificação Nebulosa em Bases de Dados Reais

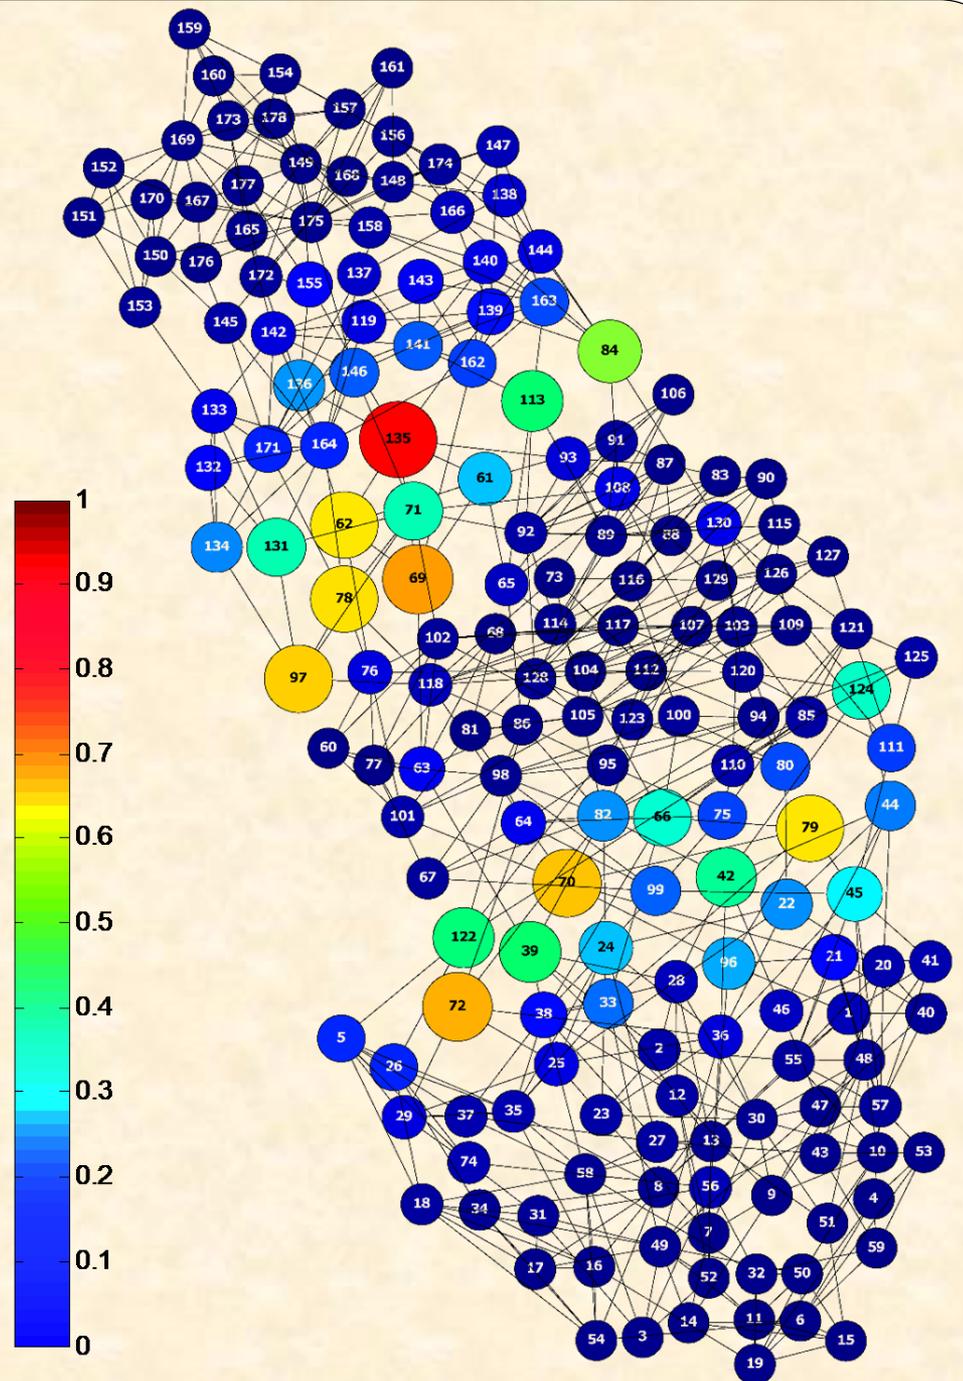
- A Base de Dados Iris. Tamanhos e cores dos nós representam o respectivo grau de sobreposição detectado pelo método proposto.



Bache, K. & Lichman, M. UCI Machine Learning Repository, 2013
[<http://archive.ics.uci.edu/ml>]. Irvine, CA:
University of California, School of Information and Computer Science.

Classificação Nebulosa em Bases de Dados Reais

- A Base de Dados Wine. Tamanhos e cores dos nós representam o respectivo grau de sobreposição detectado pelo método proposto.



Bache, K. & Lichman, M. (2013). UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science.

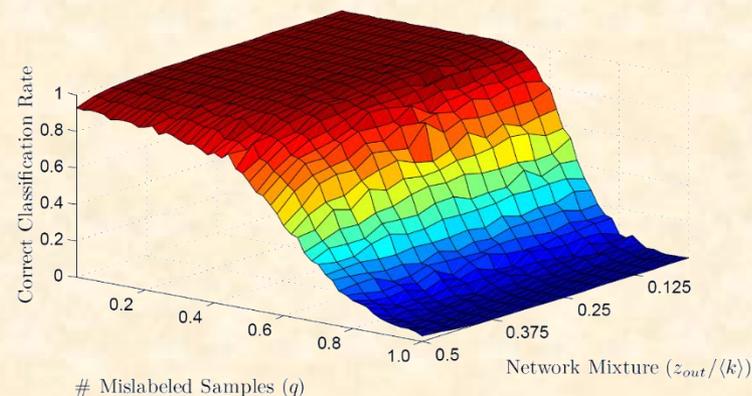
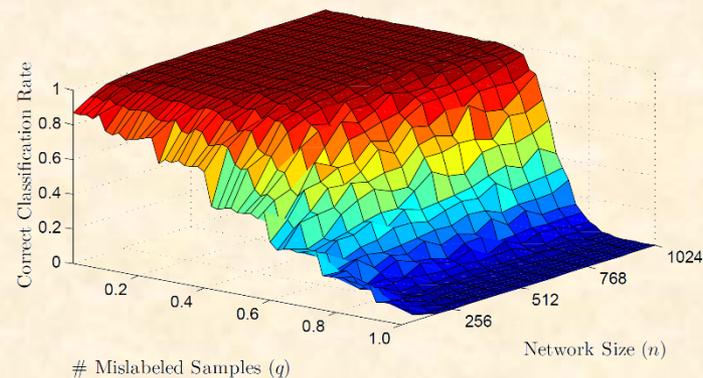
Aprendizado Semi-Supervisionado com Dados Imperfeitos

BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves. **Particle Competition and Cooperation for Semi-Supervised Learning with Label Noise.** *Neurocomputing (Amsterdam)*, v.160, p.63 - 72, 2015.
<http://dx.doi.org/10.1016/j.neucom.2014.08.082>

BREVE, Fabricio Aparecido ; ZHAO, Liang . **Particle Competition and Cooperation to Prevent Error Propagation from Misabeled Data in Semi-Supervised Learning.** In: XII Brazilian Symposium on Neural Network (SBRN 2012), The Brazilian Conference on Intelligent System (BRACIS 2012), 2012, Curitiba, Paraná. *Proceedings of the XII Brazilian Symposium on Neural Network (SBRN 2012) and The Brazilian Conference on Intelligent System (BRACIS 2012)*, 2012.
<http://dx.doi.org/10.1109/SBRN.2012.16>

BREVE, Fabricio; ZHAO, Liang; QUILES, Marcos Gonçalves. **Semi-Supervised Learning from Imperfect Data through Particle Cooperation and Competition** In: IEEE World Congress on Computational Intelligence (IEEE WCCI 2010) - International Joint Conference on Neural Networks (IJCNN 2010), 2010, Barcelona, Espanha. *Proceedings of 2010 World Congress on Computational Intelligence (WCCI 2010)*. Los Alamitos, California: IEEE Computer Society, 2010. p.3686 - 3693.
<http://dx.doi.org/10.1109/IJCNN.2010.5596659>

BREVE, Fabricio Aparecido, ZHAO, Liang . **Preventing Error Propagation in Semi-Supervised Learning Using Teams of Walking Particles** In: X Congresso Brasileiro de Inteligência Computacional, 2011, Fortaleza, Ceará. *Anais do X Congresso Brasileiro de Inteligência Computacional*, 2011.



Aprendizado Semi-Supervisionado com Dados Imperfeitos

- Qualidade dos dados de treinamento é muito importante.
- A maioria dos algoritmos assume que os rótulos dos dados de entrada são completamente confiáveis.
- Mas na prática, é comum existirem dados com rótulos errados.
- Rótulos errados podem se propagar por uma grande parte ou por toda a base de dados.
- Apesar de sua importância, este é um tópico que tem recebido pouca atenção dos pesquisadores.

D. K. Slonim. “*Learning from Imperfect Data in Theory and Practice*”. Technical report, Cambridge, MA, USA, 1996.

T. Krishnan. “**Efficiency of learning with imperfect supervision**”. *Pattern Recognition*, vol. 21, no. 2, pp. 183–188, 1988.

P. Hartono and S. Hashimoto. “**Learning from imperfect data**”. *Applied Soft Computing*, vol. 7, no. 1, pp. 353–363, 2007.

M.-R. Amini and P. Gallinari. “**Semi-supervised learning with an imperfect supervisor**”. *Knowledge and Information Systems*, vol. 8, no. 4, pp. 385–413, 2005.

M.-R. Amini and P. Gallinari. “**Semi-supervised learning with explicit misclassification modeling**”. In *IJCAI’03: Proceedings of the 18th international joint conference on Artificial intelligence*, pp. 555–560, San Francisco, CA, USA, 2003. Morgan Kaufmann Publishers Inc.



Dados de Treinamento: **Classe “Cachorros”**

Modelo de Partículas aplicado ao Aprendizado Semi-Supervisionado com Dados Imperfeitos

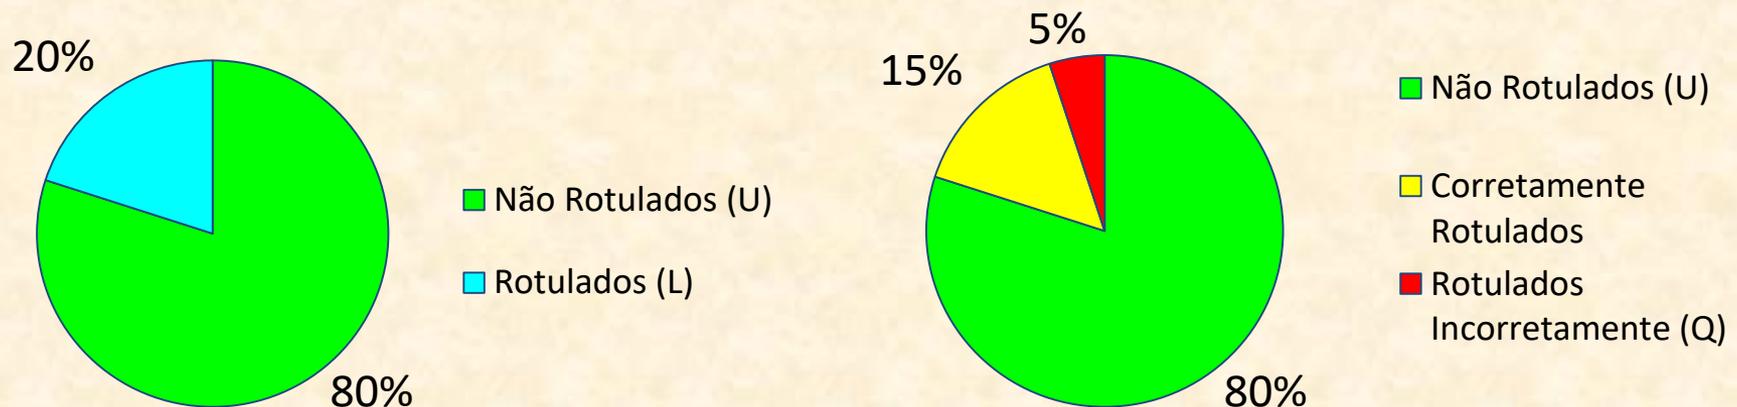
- Modelo bastante robusto a presença de dados com rótulos errados.
- Última extensão desta categoria (Breve, 2015) apresenta as seguintes características:
 - Nós rotulados priorizam conexões com os k nós rotulados mais próximos da mesma classe.
 - Todos os potenciais de nós são variáveis, inclusive o dos nós pré-rotulados.
 - Regra de Reinício
 - Reinicia posição das partículas, força, níveis de domínio, tabelas de distância, etc. periodicamente.
 - Guarda níveis de domínio antes do reinício para fazer média no final
- Tais extensões proporcionam:
 - Saída rápida das partículas dos nós com rótulos errados, que deixam a área inimiga e passam a auxiliar seus companheiros de equipe.
 - Re-rotulagem dos nós com rótulos errados.
 - Minimiza efeito de troca de território de versões anteriores.

BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves. **Particle Competition and Cooperation for Semi-Supervised Learning with Label Noise**. *Neurocomputing (Amsterdam)*, v.160, p.63 - 72, 2015.

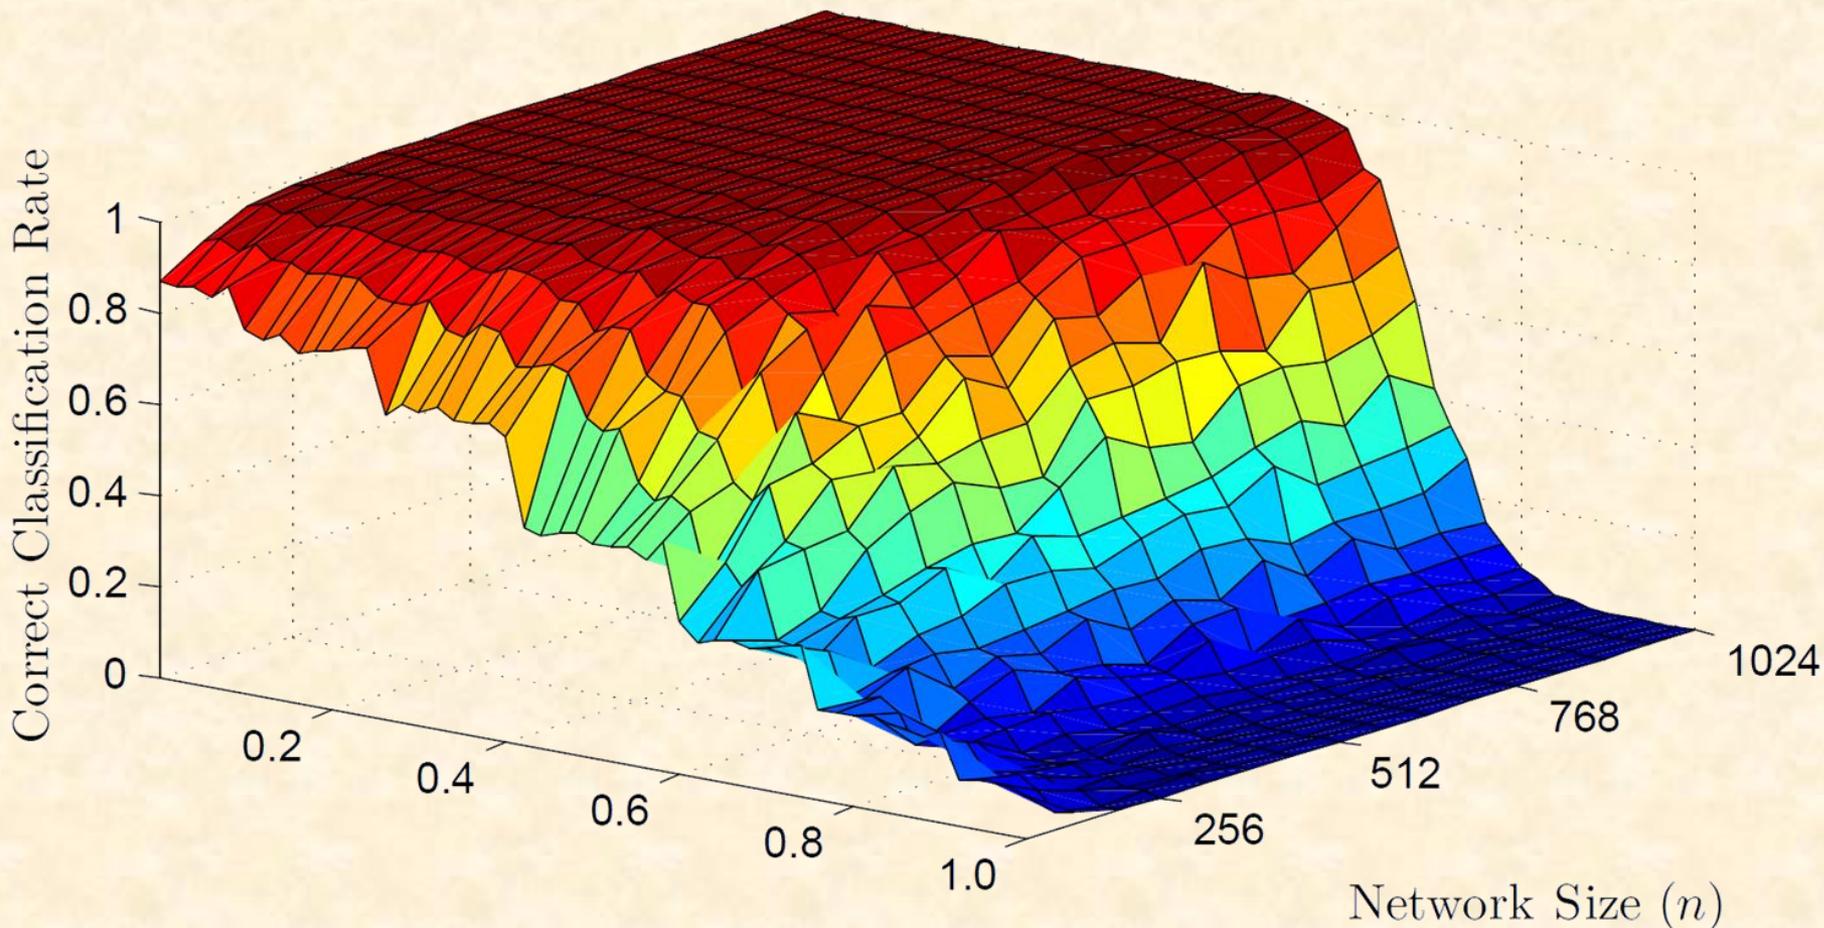
<http://dx.doi.org/10.1016/j.neucom.2014.08.082>

Simulações em redes contendo nós com rótulos errados.

- Redes são geradas com:
 - Diferentes tamanhos e misturas
 - Elementos divididos em 4 classes
 - Conjunto de nós N
 - Subconjunto de nós rotulados $L \subset N$
 - Subconjunto de nós com rótulos errados $Q \subset L \subset N$



Simulação: Redes com Diferentes Tamanhos

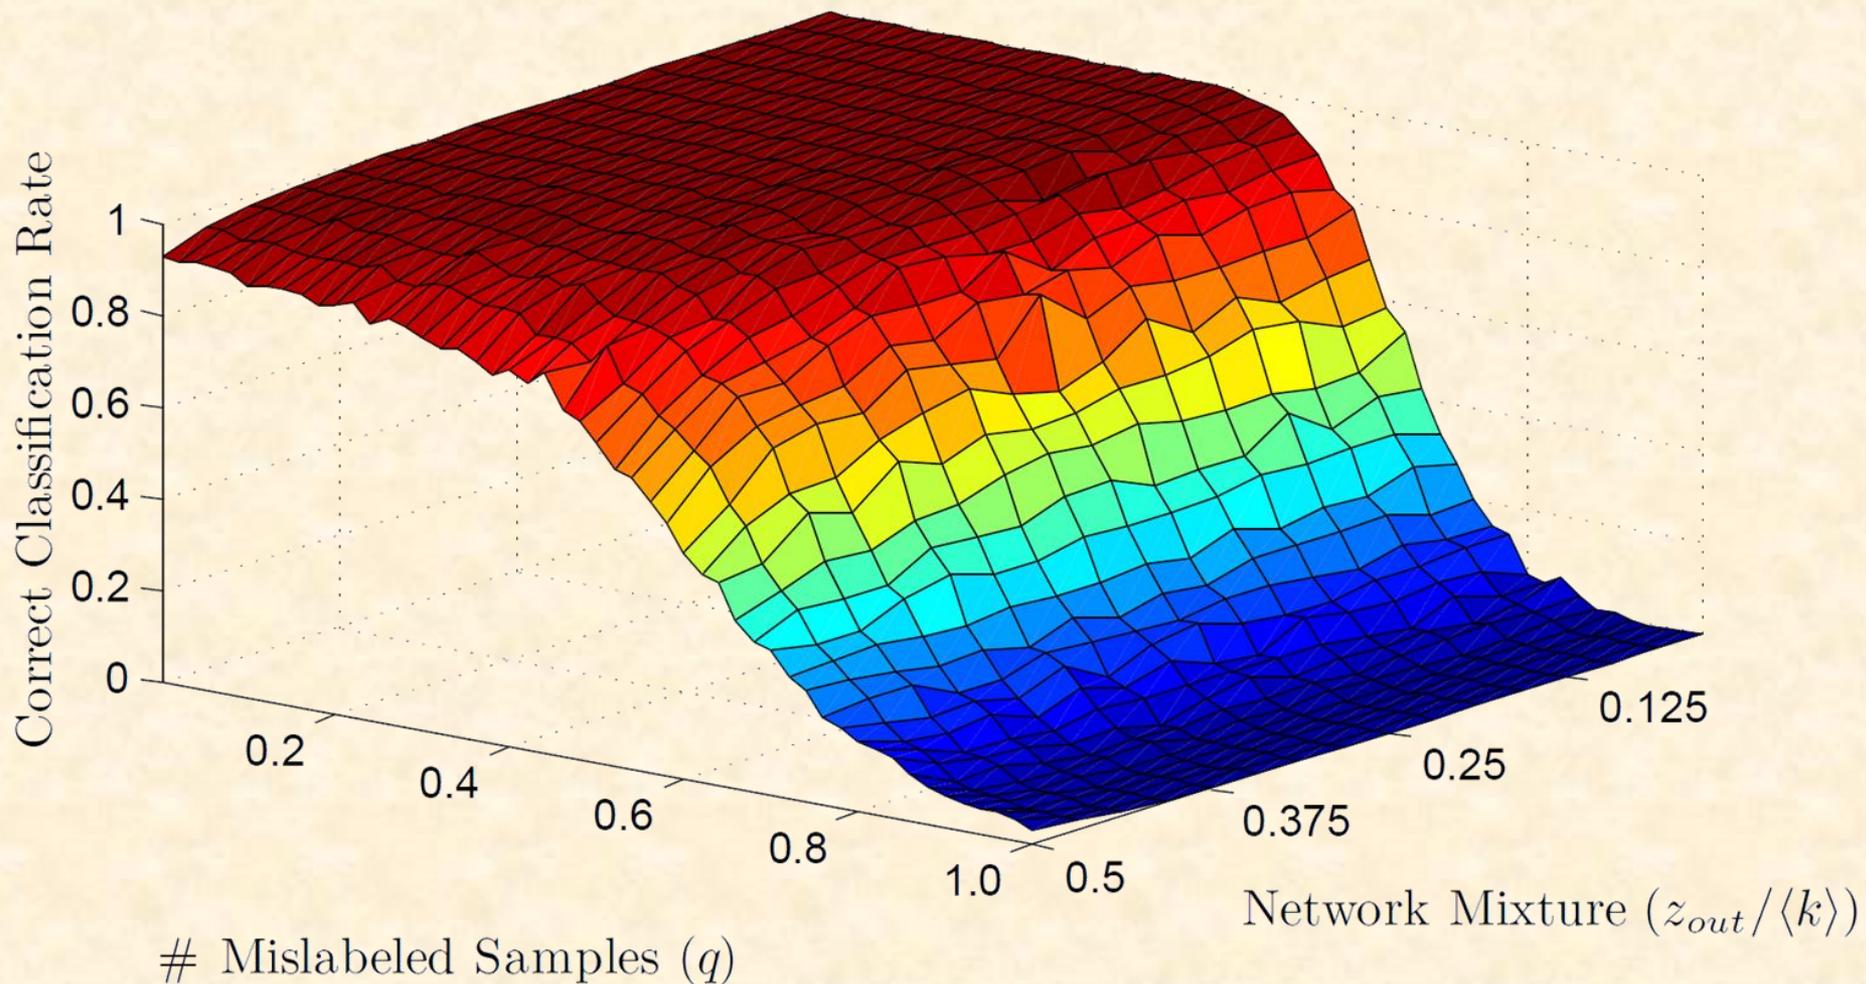


Mislabeled Samples (q)

Taxa de Classificação Correta com diferentes tamanhos de redes e diferentes tamanhos do subconjunto de nós com rótulos errados.

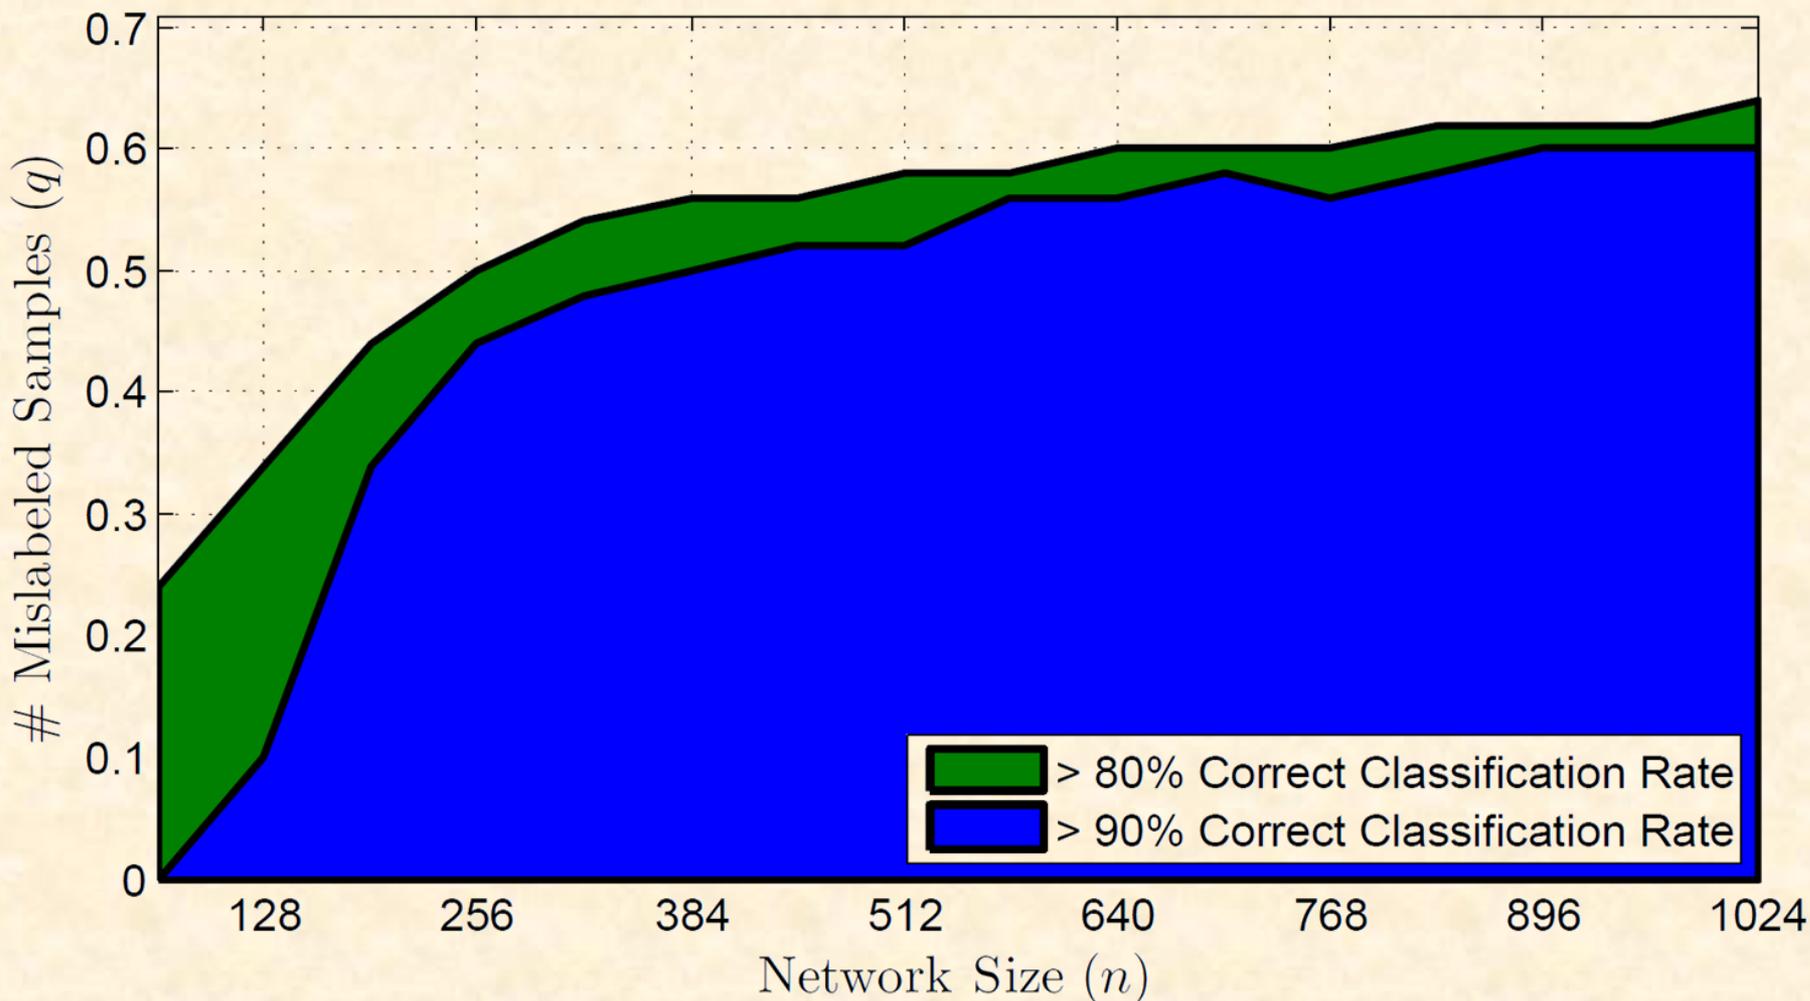
$$\langle k \rangle = n/8, \quad z_{out}/\langle k \rangle = 0,25, \quad l/n = 0,1$$

Simulação: Redes com Diferentes Misturas



Taxa de Classificação Correta com diferentes misturas de redes e diferentes tamanhos do subconjunto de nós com rótulos errados,
 $n = 512$, $\langle k \rangle = 64$, $l = 64$

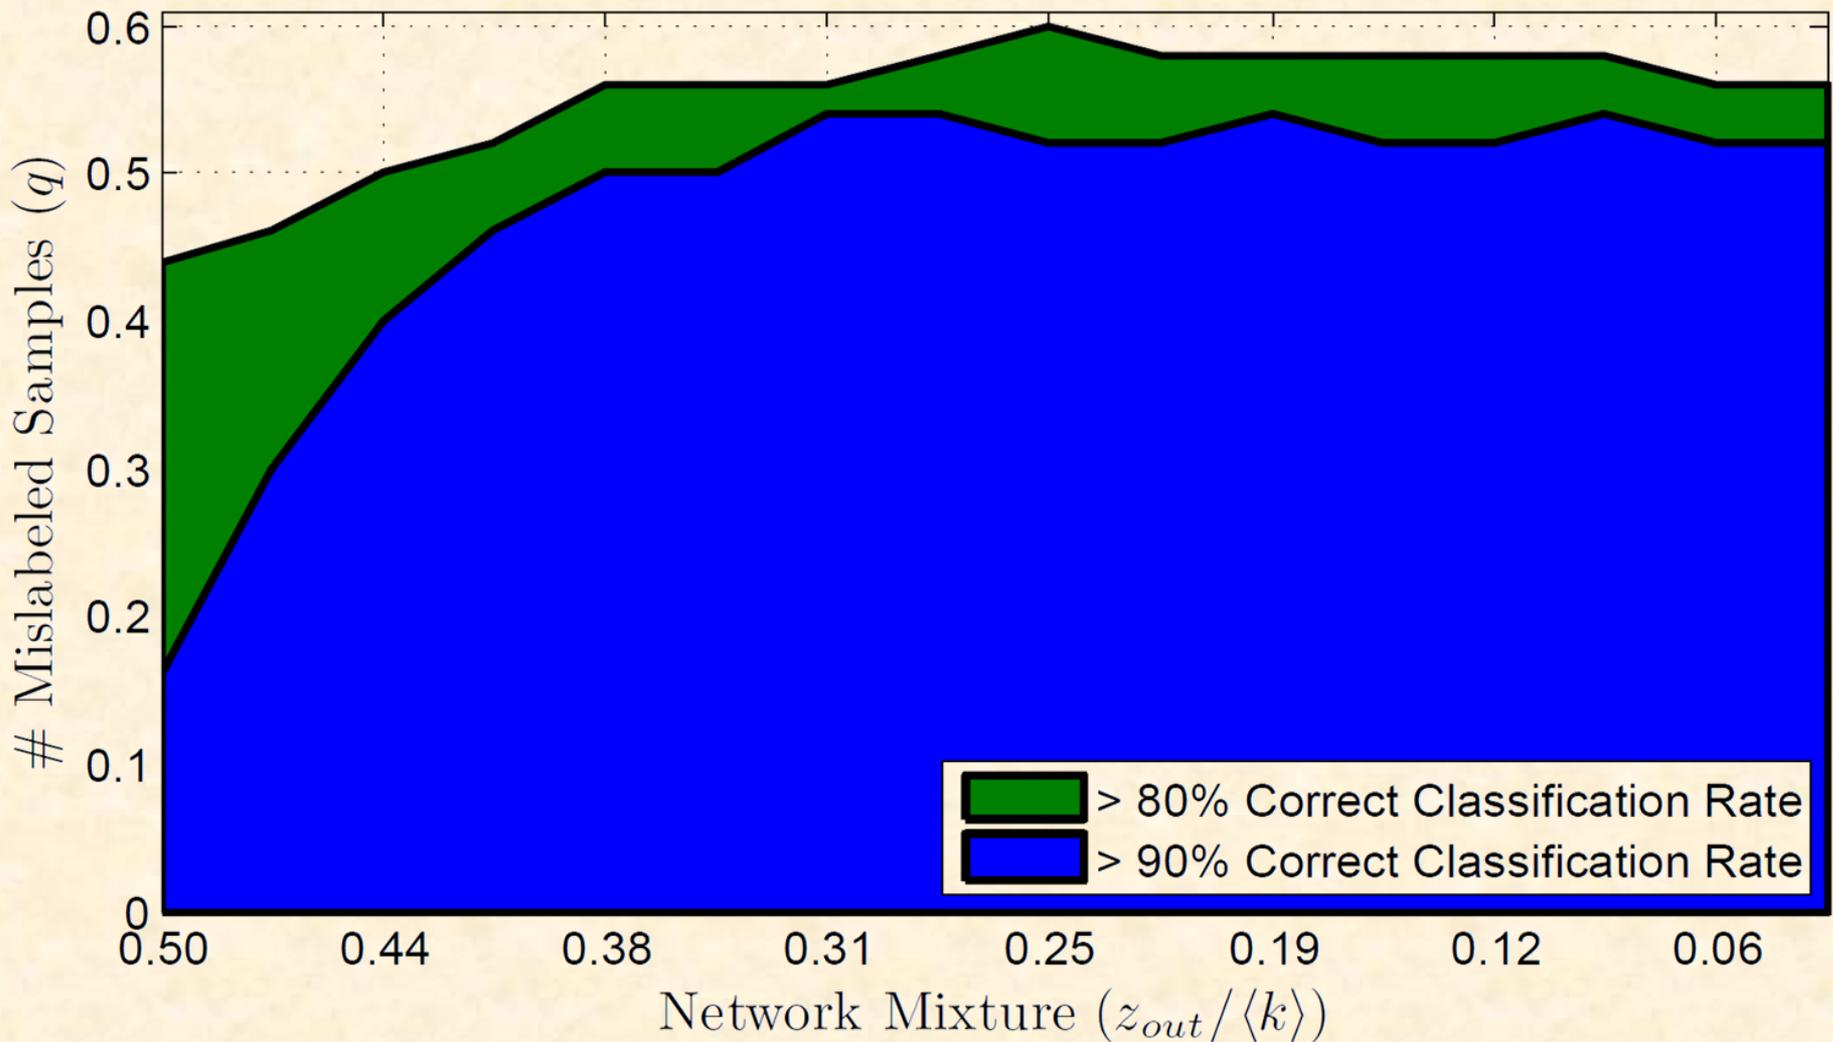
Simulação: Redes com Diferentes Tamanhos



Tamanho máximo do subconjunto de dados rotulados que permite 80% e 90% de taxa de classificação correta com diferentes tamanhos de redes

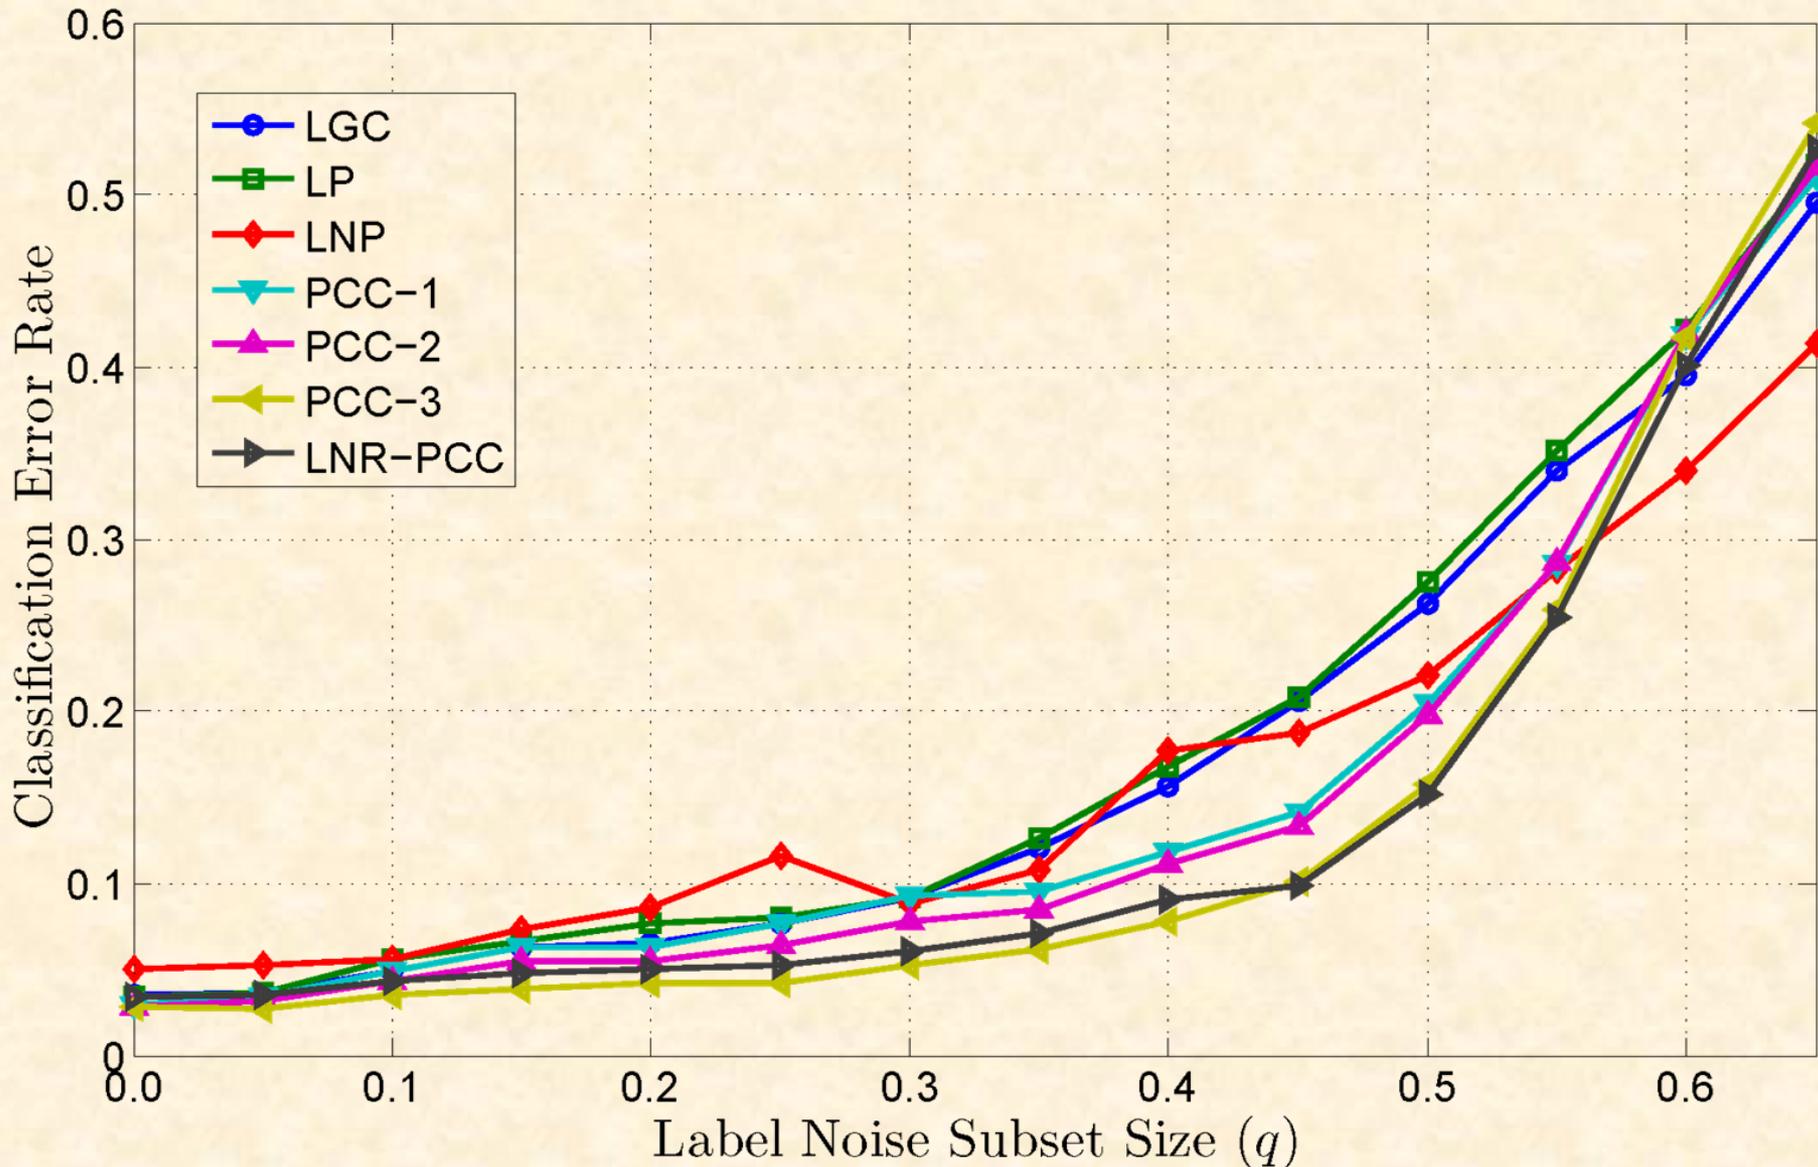
$$\langle k \rangle = n/8, \quad z_{out}/\langle k \rangle = 0,25, \quad l/n = 0,1$$

Simulação: Redes com Diferentes Misturas



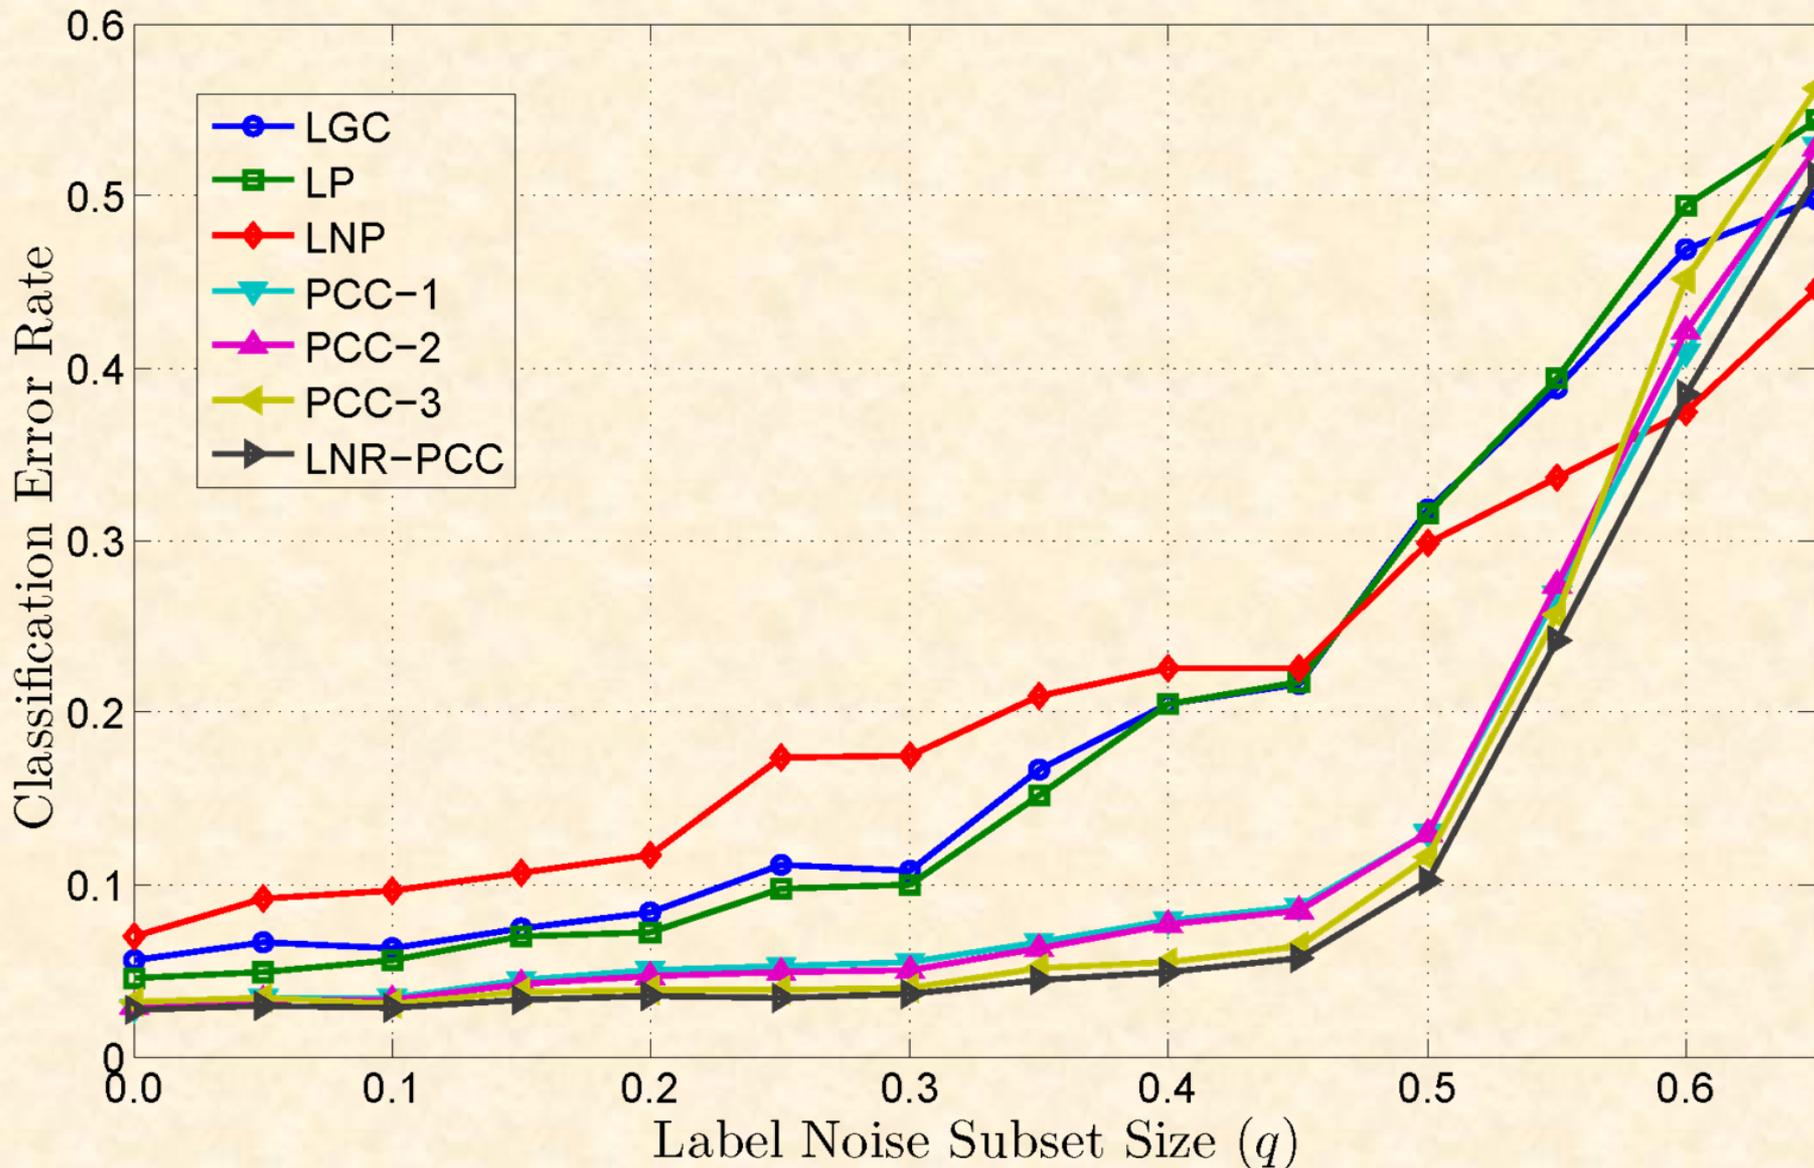
Tamanho máximo do subconjunto de dados rotulados que permite 80% e 90% de taxa de classificação correta com diferentes misturas de redes, $n = 512$, $\langle k \rangle = 64$, $l = 64$

Simulação: Iris



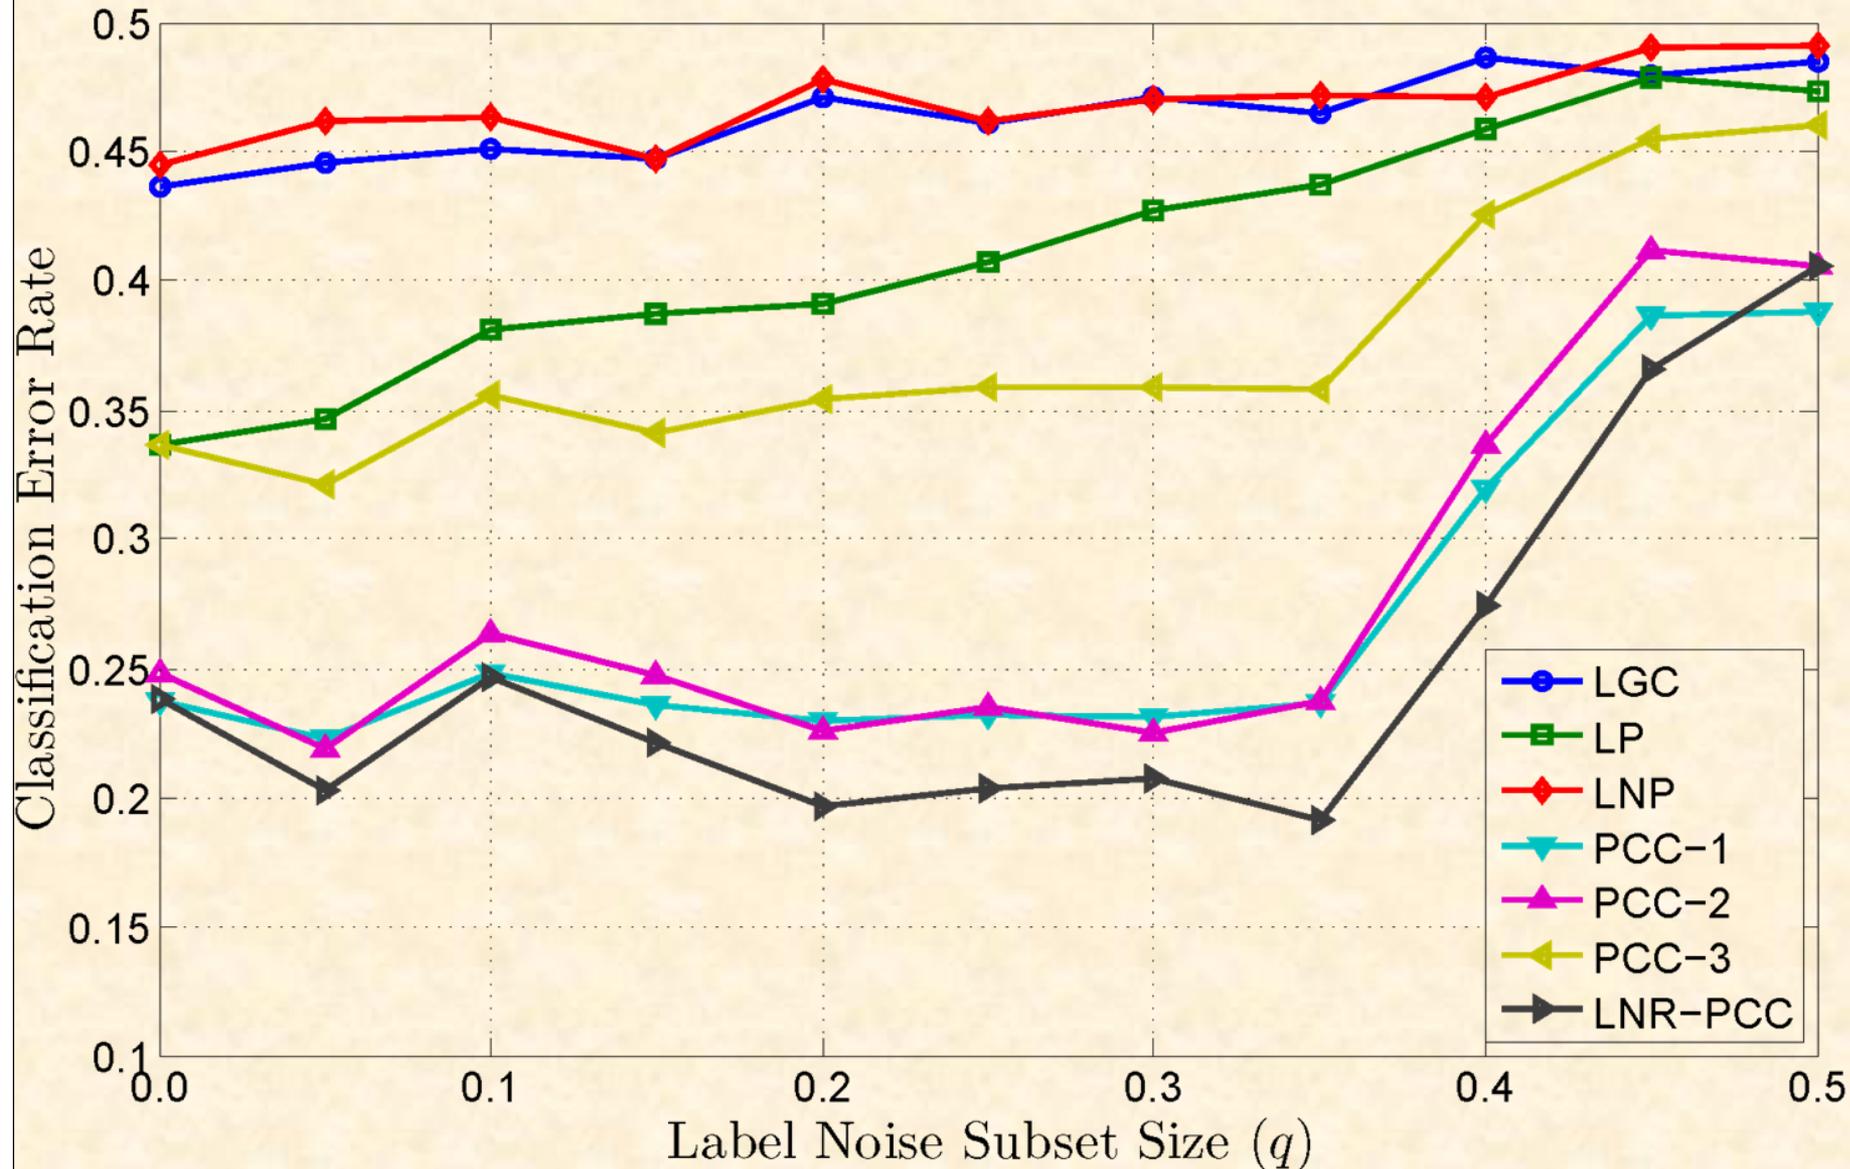
Taxa de Erro de Classificação no conjunto de dados Iris com diferentes tamanhos do subconjunto de dados com rótulos errados. 150 amostras, 40 rotuladas.

Simulação: Wine



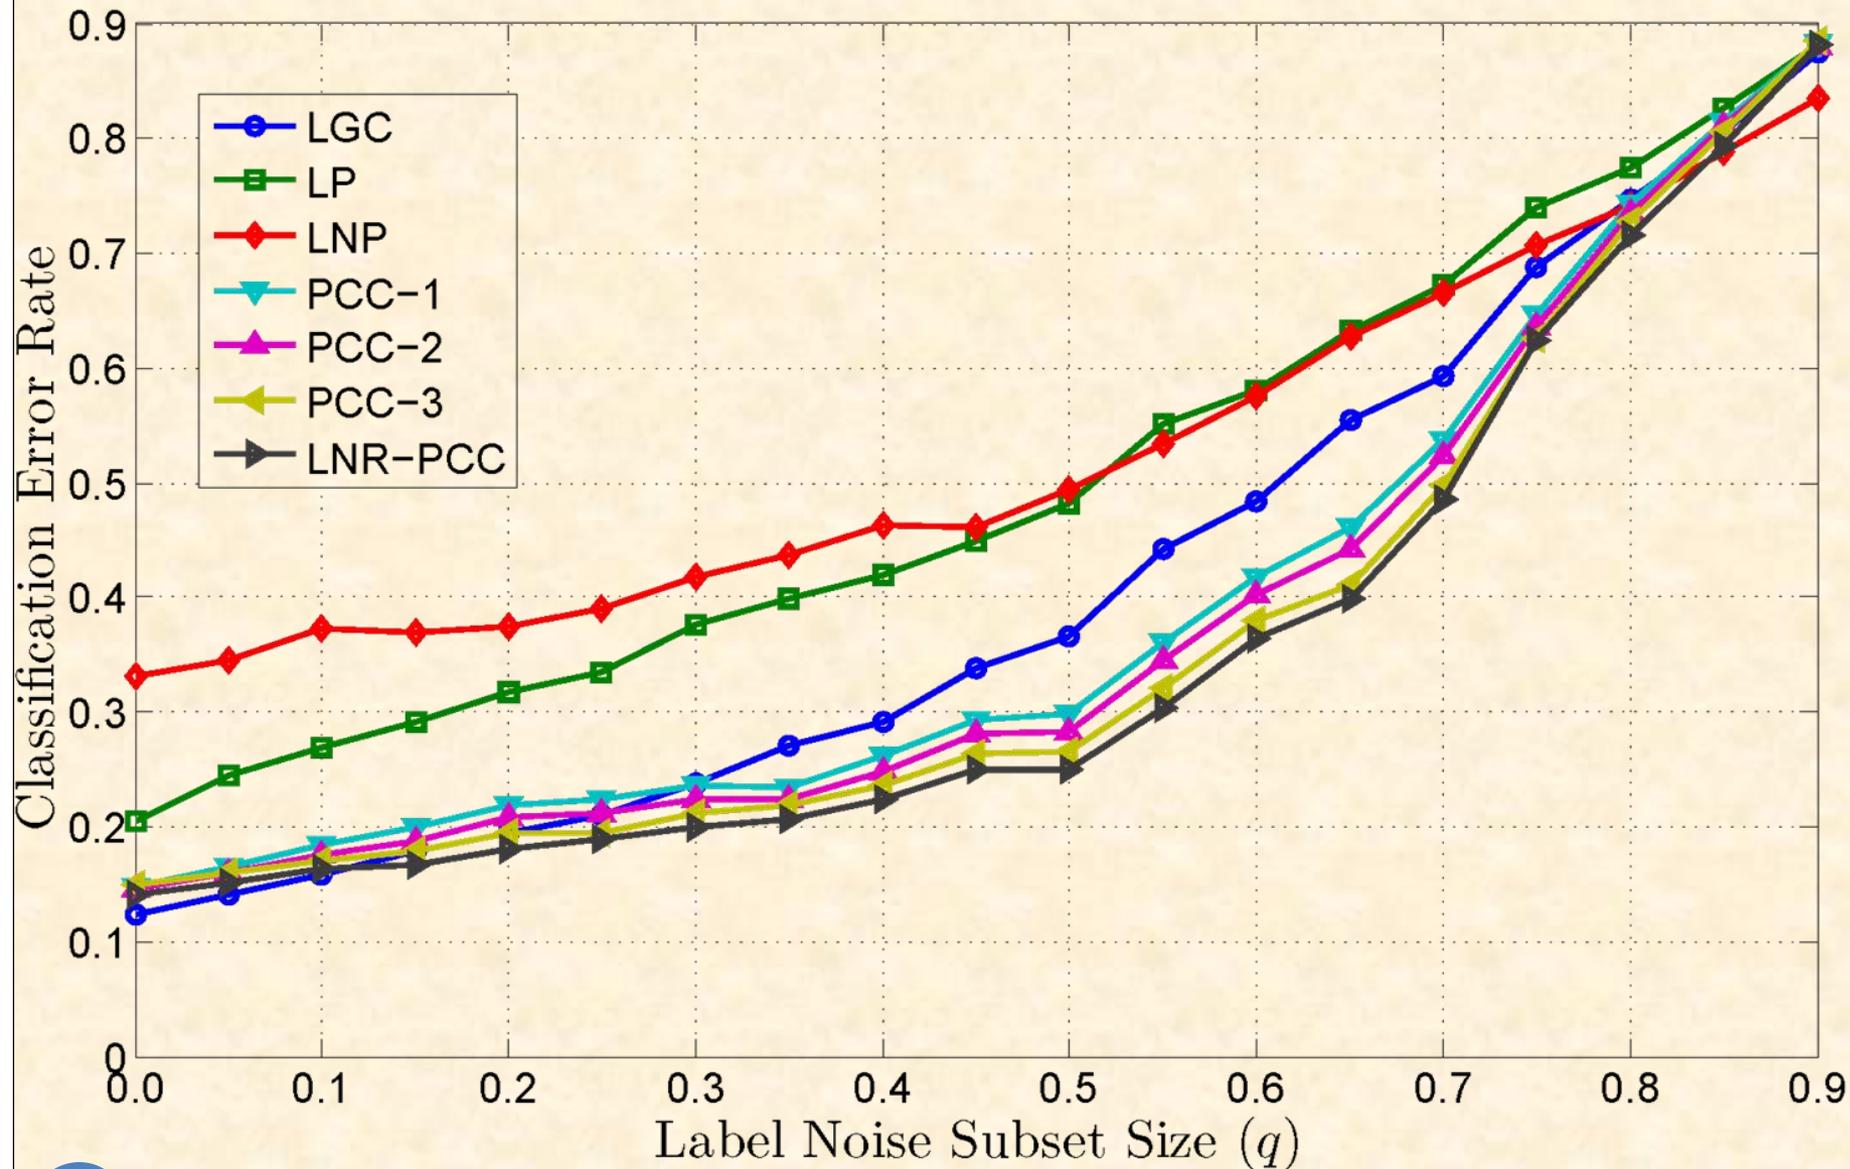
Taxa de Erro de Classificação o conjunto de dados Wine, com diferentes tamanhos do subconjunto de dados com rótulos errados. 178 amostras, 40 rotuladas.

Simulação: g241c

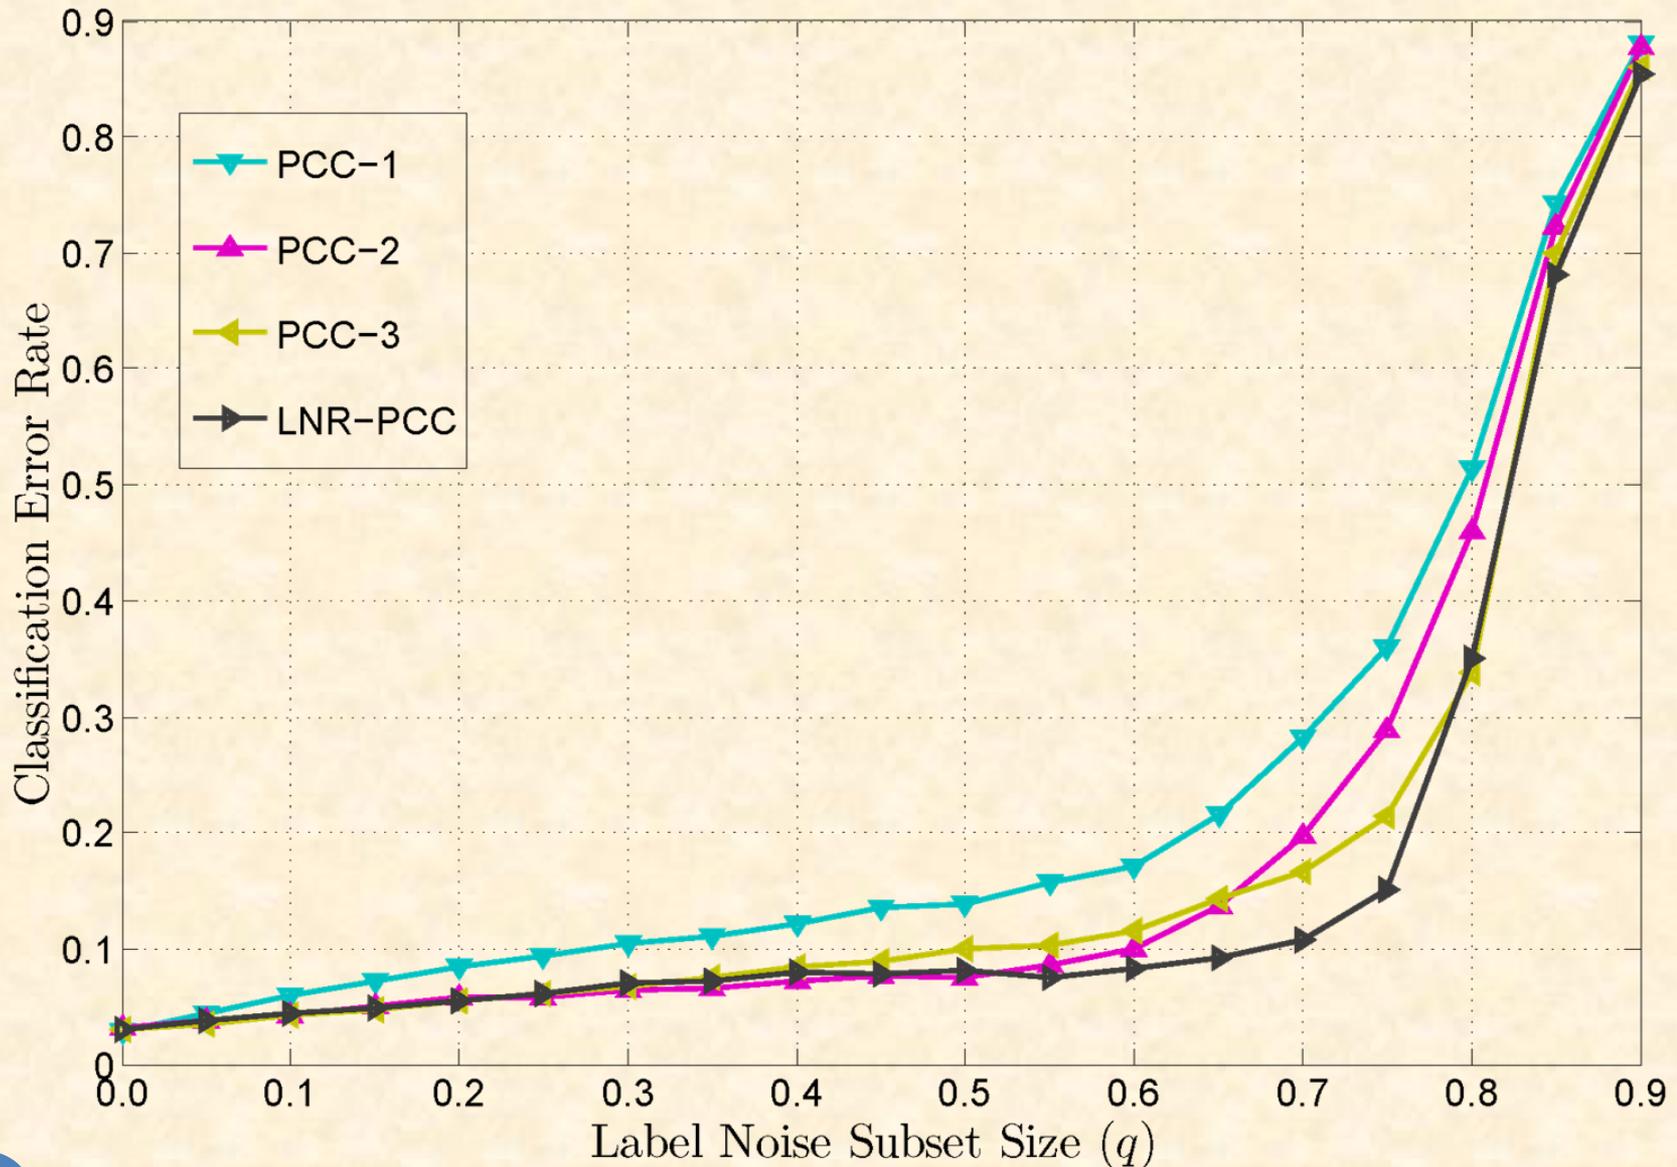


Taxa de Erro de Classificação o conjunto de dados g241c, com diferentes tamanhos do subconjunto de dados com rótulos errados. 1500 amostras, 100 rotuladas.

Simulação: Semeion Handwritten Digit



Simulação: Optical Recognition of Handwritten Digits



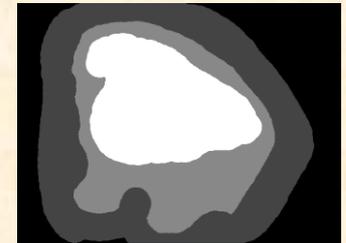
Segmentação Interativa de Imagens

BREVE, Fabricio Aparecido; QUILES, Marcos Gonçalves; ZHAO, Liang. **Interactive Image Segmentation using Particle Competition and Cooperation** In: The International Joint Conference on Neural Networks (IJCNN2015), 2015, Killarney, Irlanda. *Proceedings of the International Joint Conference on Neural Networks (IJCNN2015)*, 2015. p.1 - 8.
<http://dx.doi.org/10.1109/IJCNN.2015.7280570>

BREVE, Fabricio Aparecido, QUILES, Marcos Gonçalves, ZHAO, Liang. **Interactive Image Segmentation of Non-contiguous Classes Using Particle Competition and Cooperation** In: 15th International Conference on Computational Science and Its Applications, ICCSA 2015, 2015, Banff, Alberta, Canadá. *Computational Science and Its Applications - ICCSA 2015 - 15th International Conference, Banff, AB, Canada, June 22-25, 2015, Proceedings, Part I*. Springer International Publishing, 2015. v.9155. p.203 - 216.
http://dx.doi.org/10.1007/978-3-319-21404-7_15

BREVE, Fabricio Aparecido. **Auto Feature Weight for Interactive Image Segmentation using Particle Competition and Cooperation** In: XI Workshop de Visão Computacional (WVC2015), 2015, São Carlos, SP, Brasil. *Proceedings - XI Workshop de Visão Computacional WVC 2015*, 2015. p.164 - 169.

BREVE, Fabricio Aparecido. **Building Networks for Image Segmentation Using Particle Competition and Cooperation** In: The 17th International Conference on Computational Science and Its Applications (ICCSA 2017), 2017, Trieste, Itália. *Computational Science and Its Applications - ICCSA 2017*. Springer International Publishing AG, 2017.



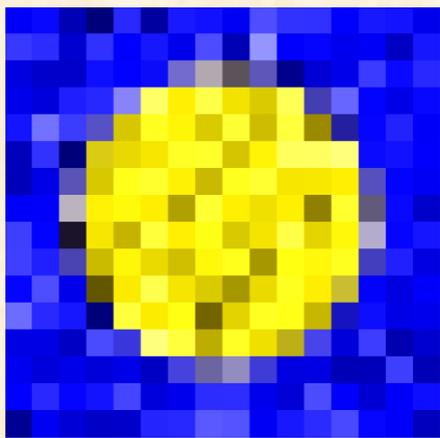
Segmentação de Imagens

- Processo de dividir uma imagem digital em partes (conjuntos de pixels), identificando regiões, objetos ou outras informações relevantes.
- Métodos de segmentação totalmente automáticos são limitados à imagens simples ou de tipos específicos.
 - Portanto, abordagens de segmentação interativa de imagens, onde o usuário oferece informações que ajudam no processo de segmentação, tem recebido interesse crescente.

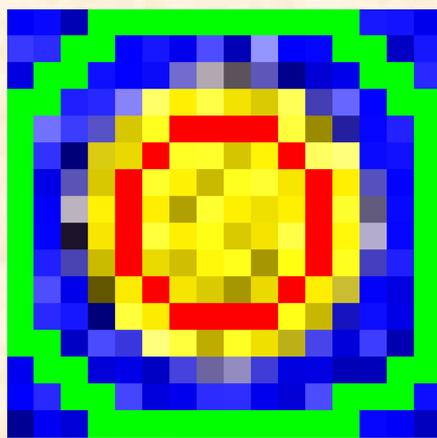
- Shapiro, L., Stockman, G.: Computer Vision. Prentice Hall (2001).
- Boykov, Y., Jolly, M.P.: Interactive graph cuts for optimal boundary & region segmentation of objects in n-d images. In: Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on. vol. 1, pp. 105-112 vol.1 (2001)
- Grady, L.: Random walks for image segmentation. Pattern Analysis and Machine Intelligence, IEEE Transactions on 28(11), 1768-1783 (Nov 2006).

Modelo de Partículas aplicado à Segmentação de Imagens

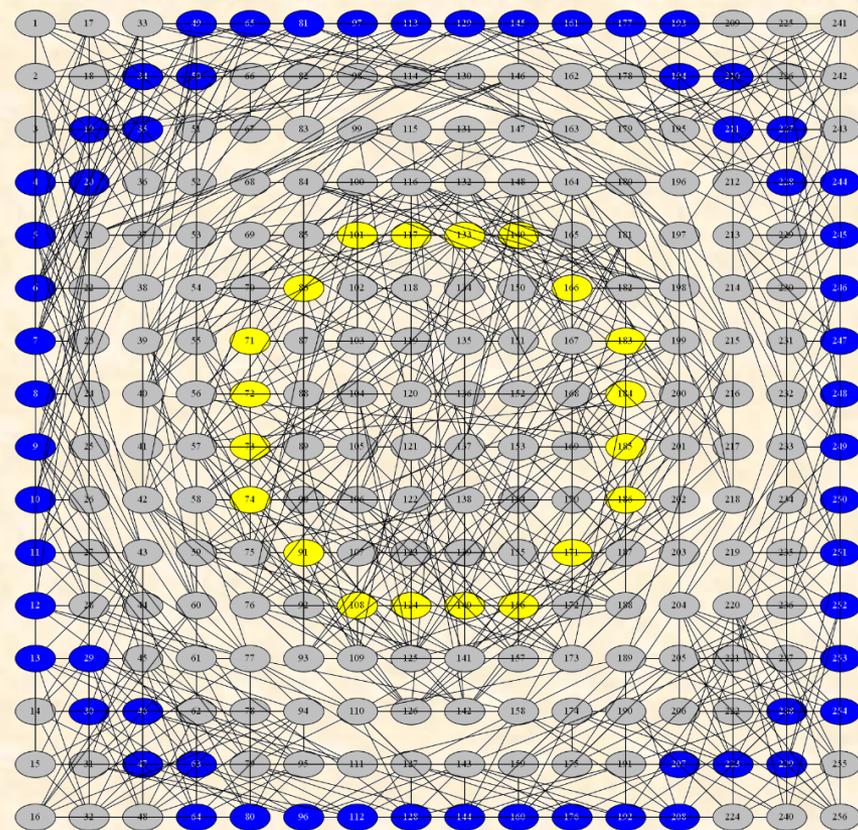
- Um grafo não direcionado e sem pesos é gerado a partir da imagem
 - Cada pixel se torna um nó do grafo
 - Cada nó é conectado com seus k vizinhos mais próximos de acordo com alguns atributos do pixel.



(a)



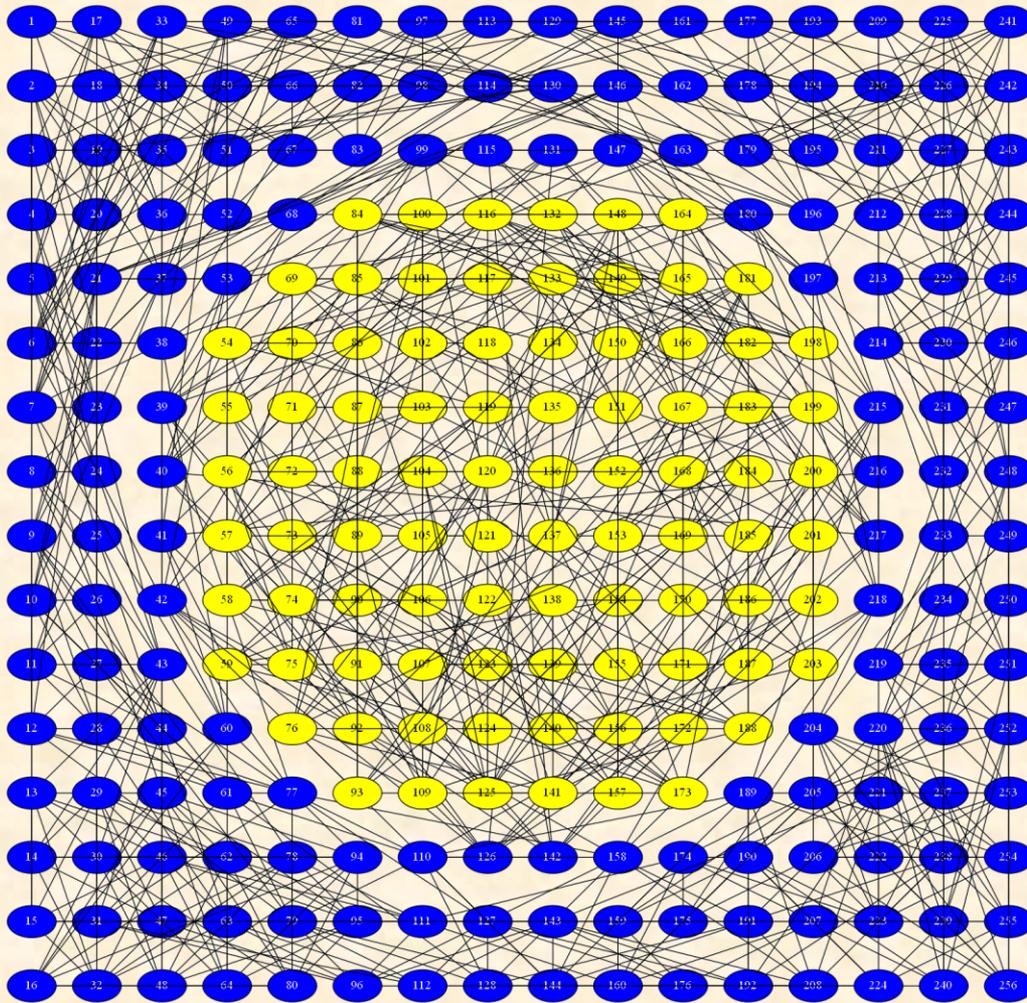
(b)



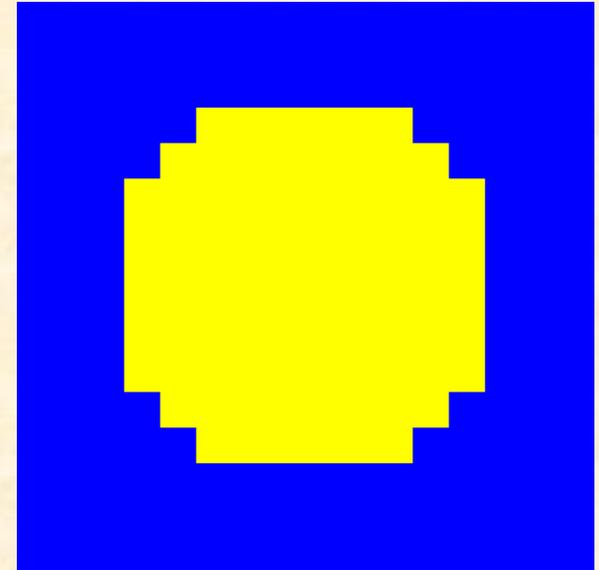
(c)

Exemplo: (a) imagem a ser segmentada (16x16 pixels); (b) imagem original com rótulos do usuário (trações verdes e vermelhos); e (c) grafo gerado a partir da imagem original, onde cada pixel corresponde a um nó do grafo. Nós rotulados são coloridos de azul e amarelo, e nós não rotulados são coloridos de cinza. Cada nó rotulado tem uma partícula atribuída a ele.

Rotulando os pixels não rotulados



(a)



(b)

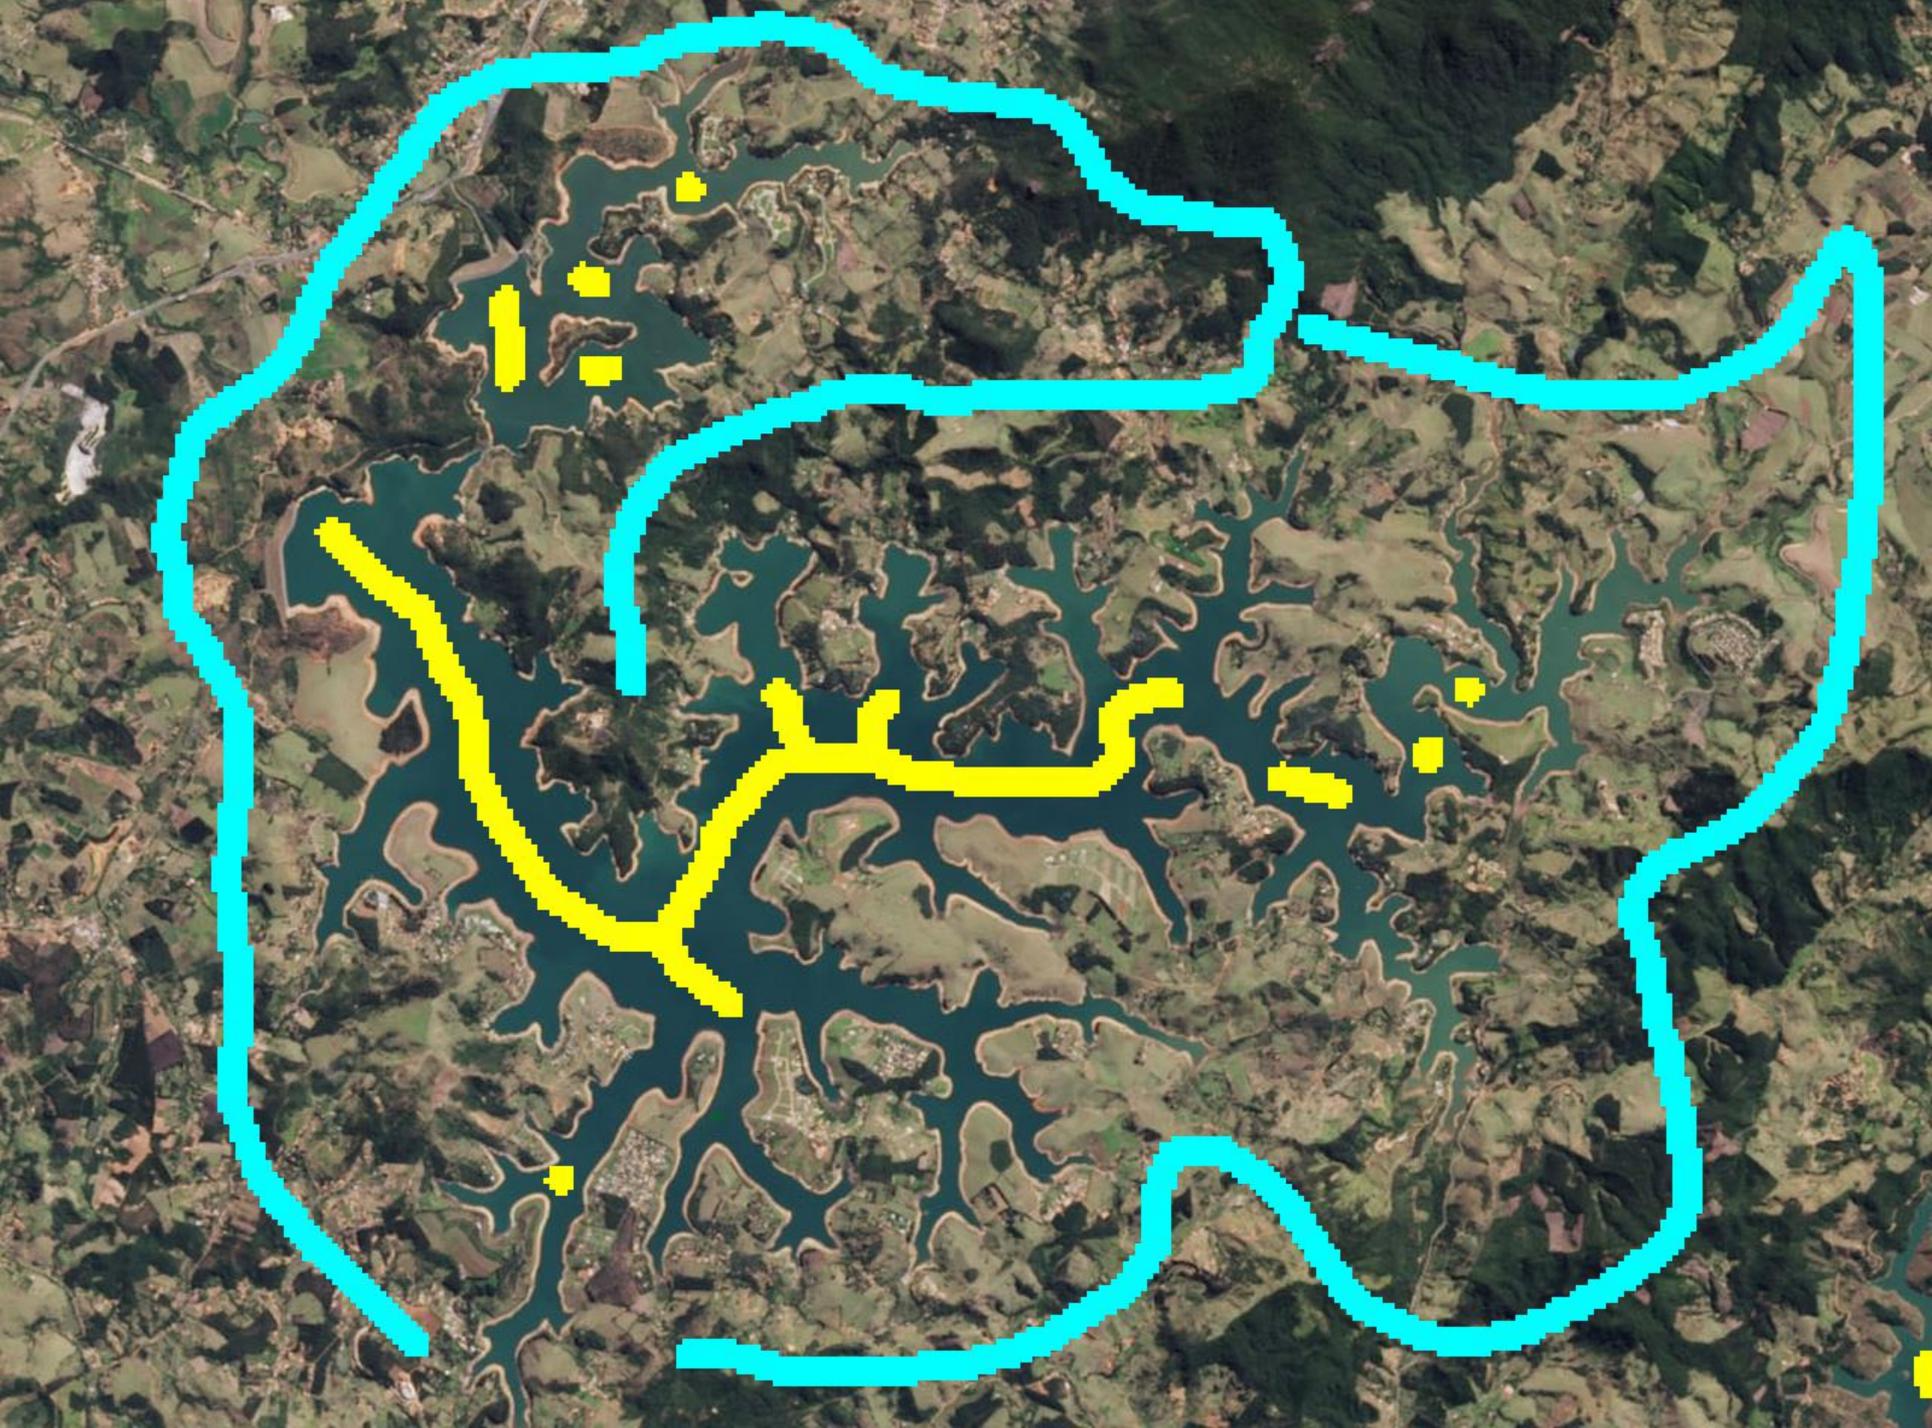
Exemplo: (a) grafo resultante após o processo de segmentação com as cores dos nós representando os rótulos que foram atribuídos a eles (b) imagem original com os pixels coloridos a partir do grafo classificado, com cada cor representando uma classe diferente

Simulações Computacionais

- 20 atributos:
 - Posição do pixel nos eixos horizontal e vertical
 - Componentes RGB (vermelho, verde, azul)
 - Componentes HSV (matiz, saturação, intensidade)
 - Média de cada componente RGB e HSV em uma janela de 3x3 pixels.
 - Desvio padrão de cada componente RGB e HSV em uma janela de 3x3 pixels
- $k = 100$

BREVE, Fabricio Aparecido, QUILES, Marcos Gonçalves, ZHAO, Liang. **Interactive Image Segmentation of Non-contiguous Classes Using Particle Competition and Cooperation** In: 15th International Conference on Computational Science and Its Applications, ICCSA 2015, 2015, Banff, Alberta, Canadá. *Computational Science and Its Applications - ICCSA 2015 - 15th International Conference, Banff, AB, Canada, June 22-25, 2015, Proceedings, Part I*. Springer International Publishing, 2015. v.9155. p.203 - 216.
http://dx.doi.org/10.1007/978-3-319-21404-7_15



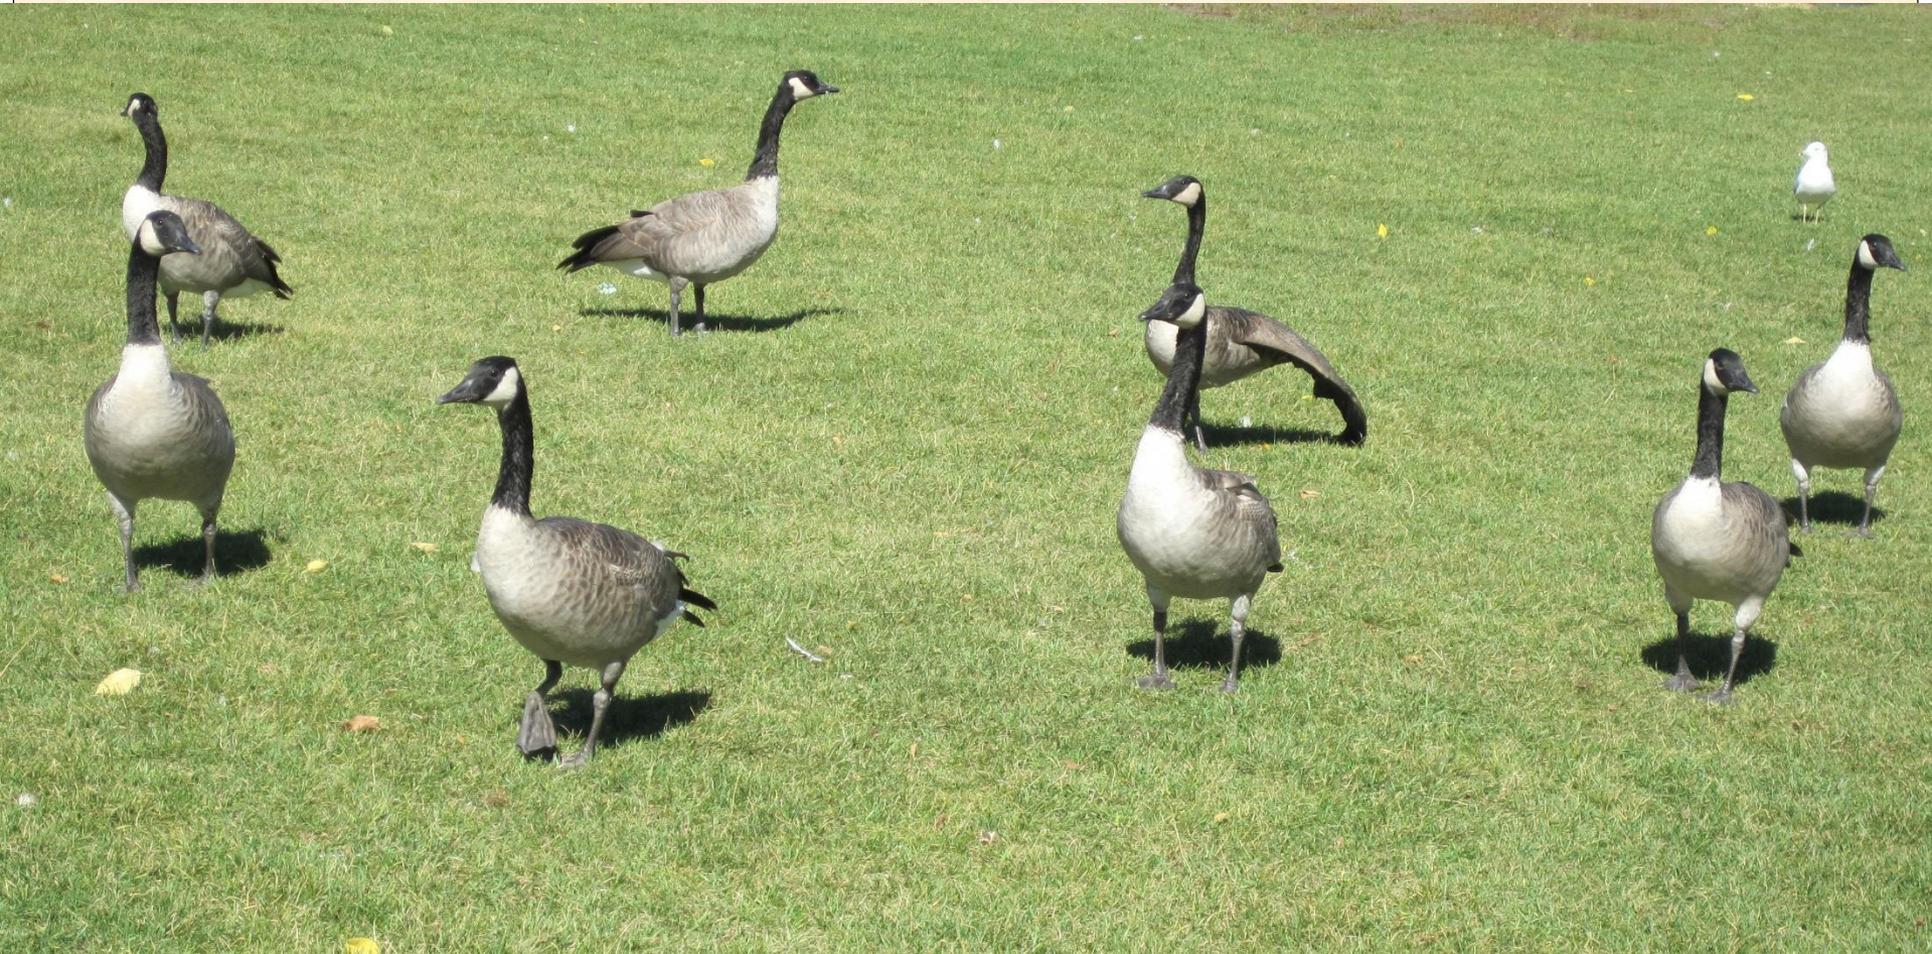




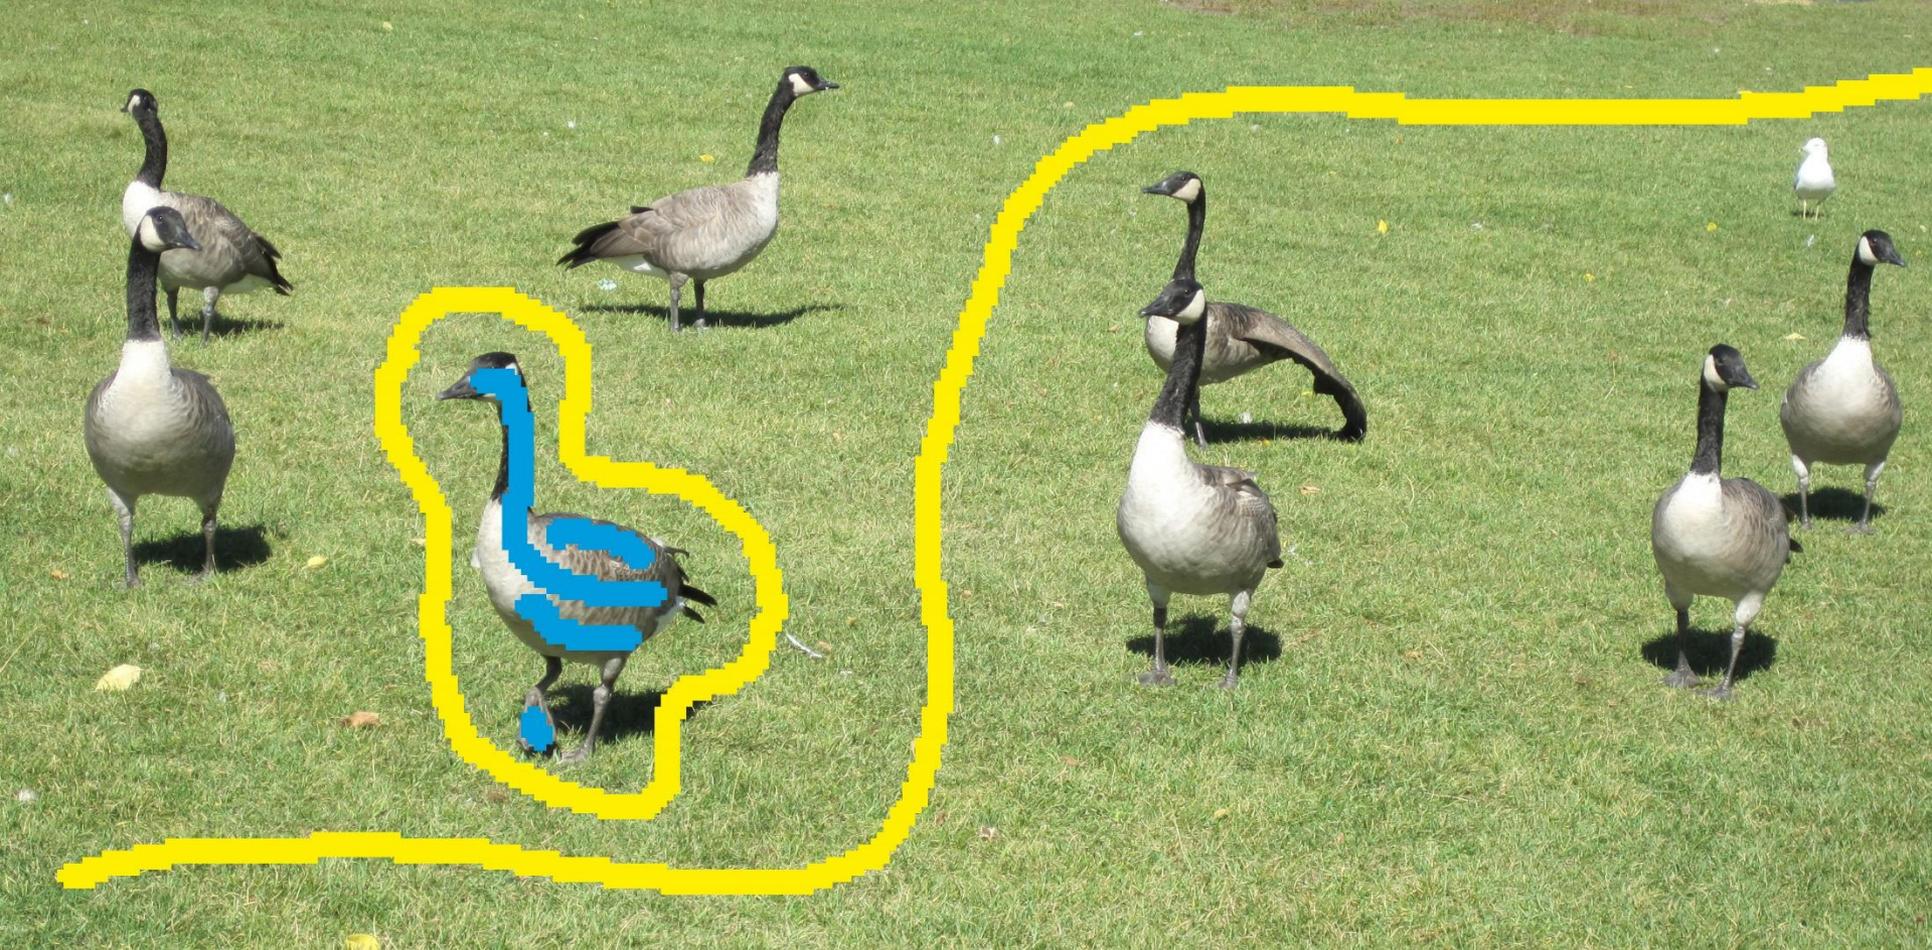


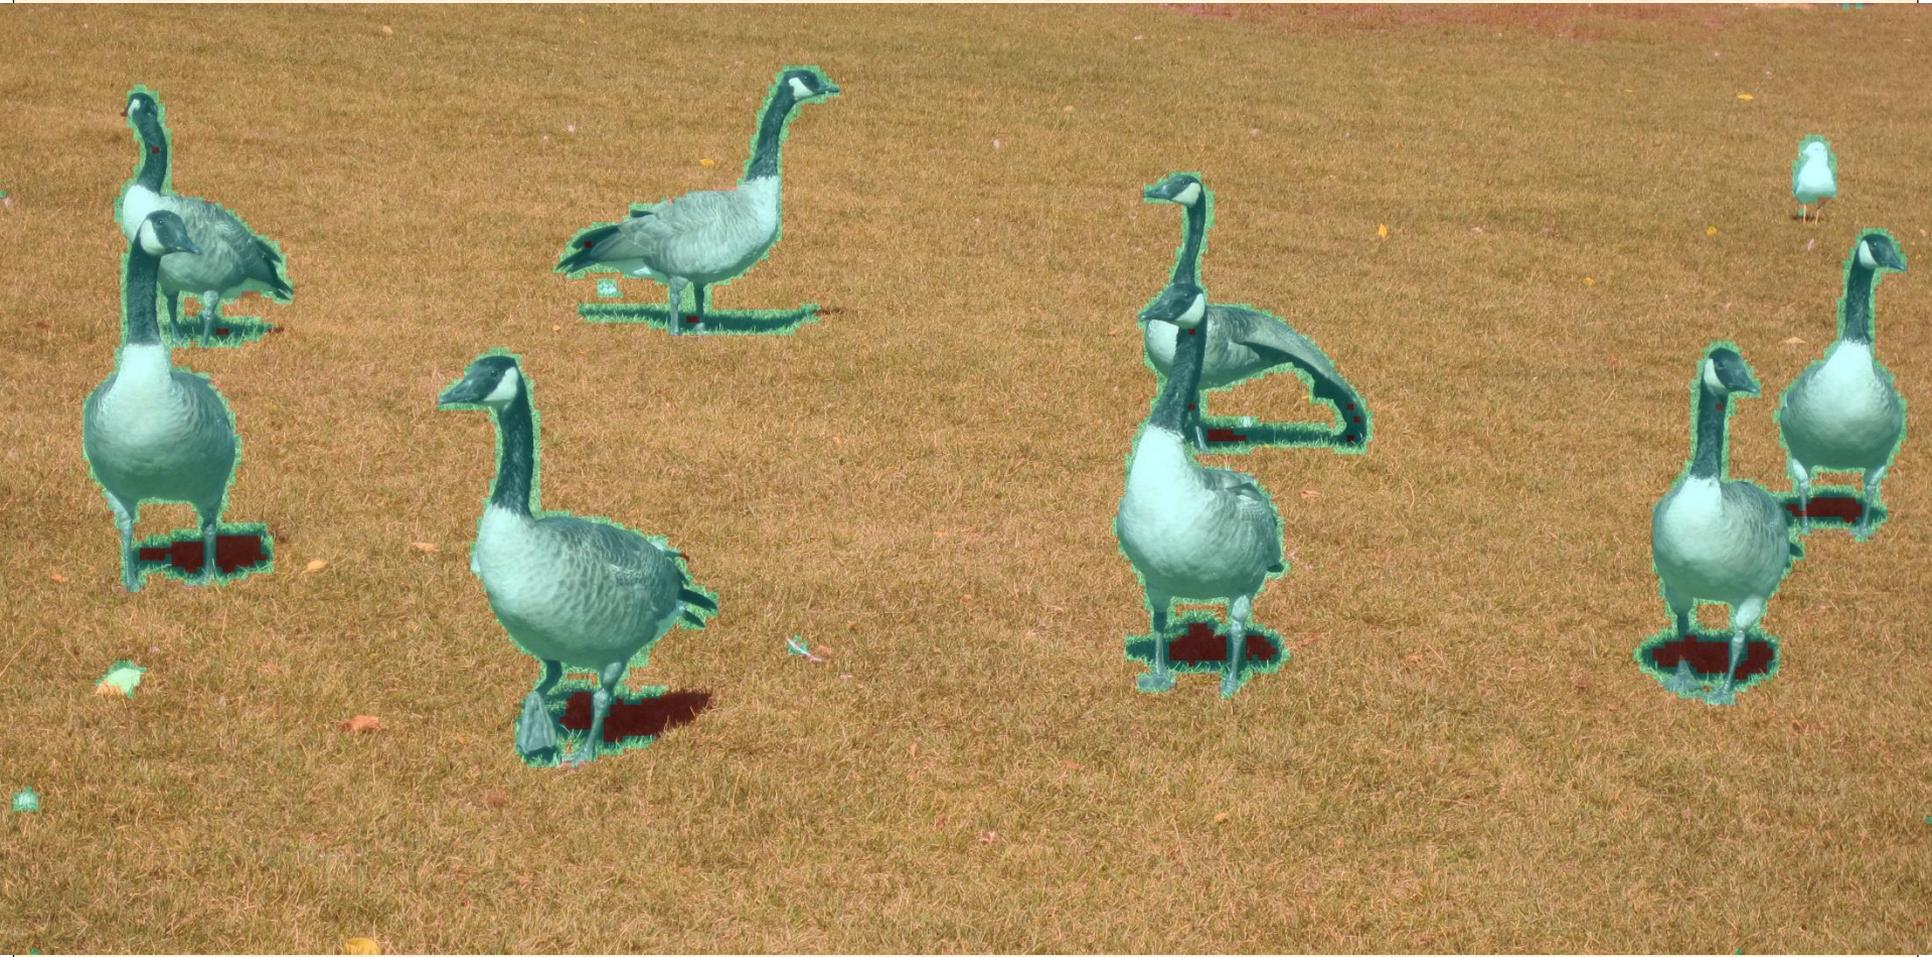






William Hawrelak Park - Edmonton - Alberta - Canadá - por Fabricio Breve





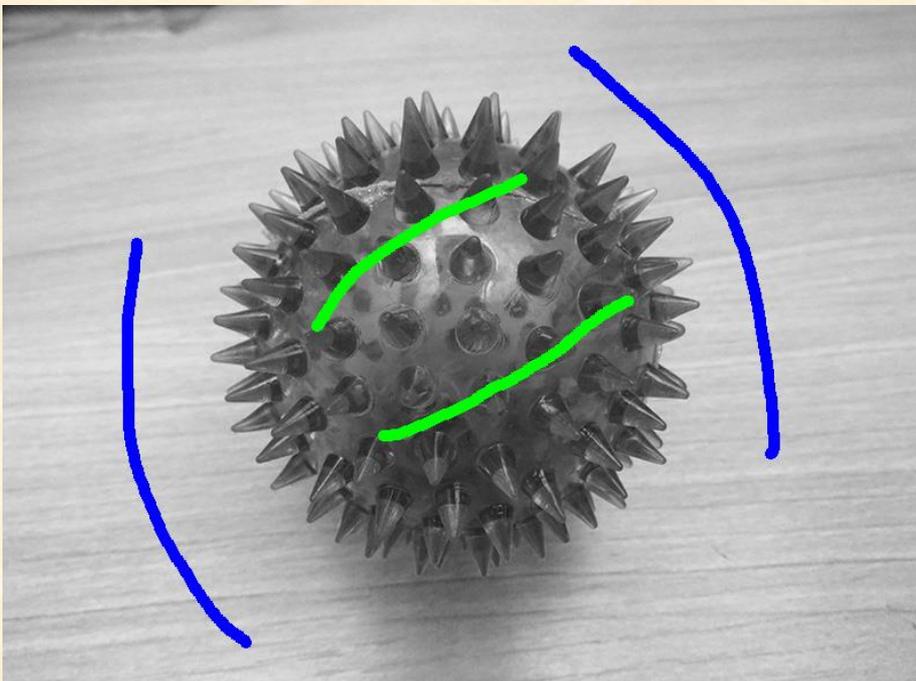
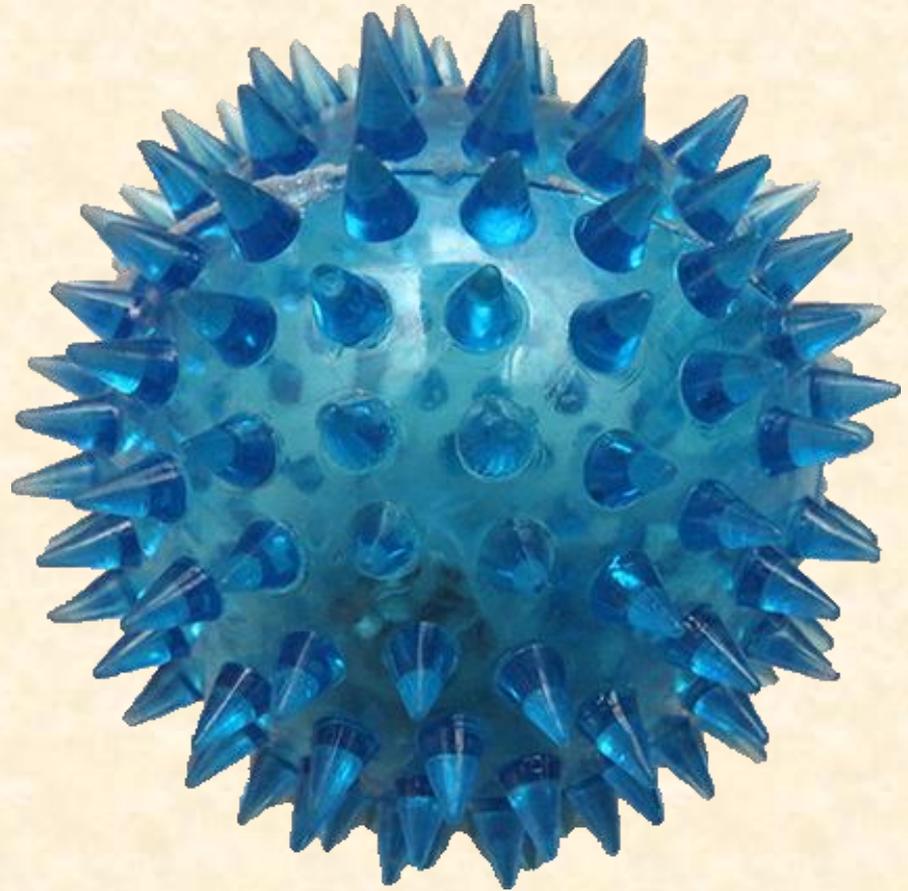
Segmentação Interativa de Imagens usando Propagação de Rótulos em Redes Complexas

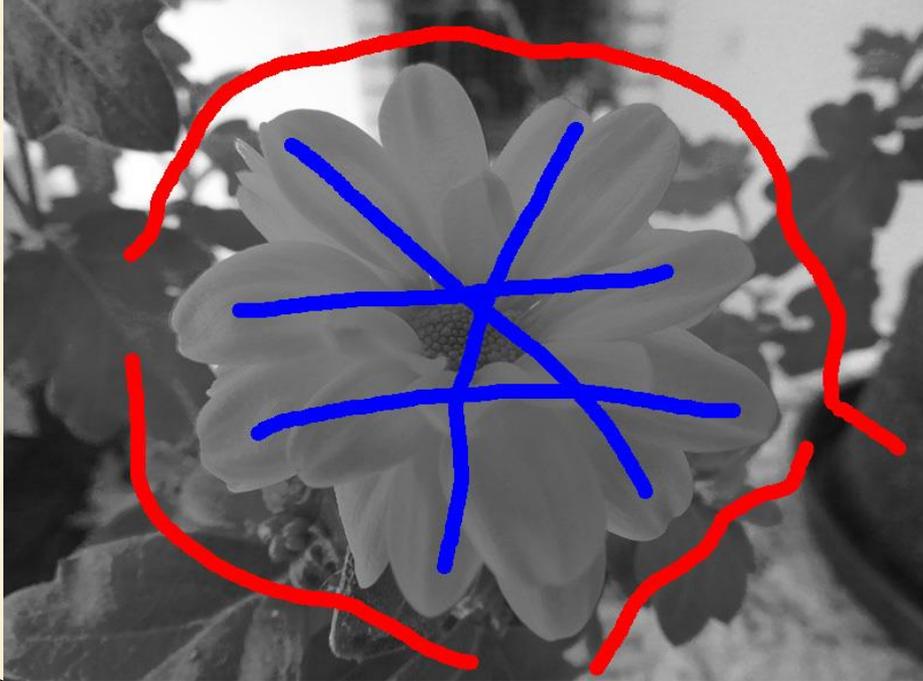
BREVE, Fabricio Aparecido. **Interactive Image Segmentation using Label Propagation through Complex Networks.** *Expert System With Applications*, v. 123, p.18 – 33, 2019.

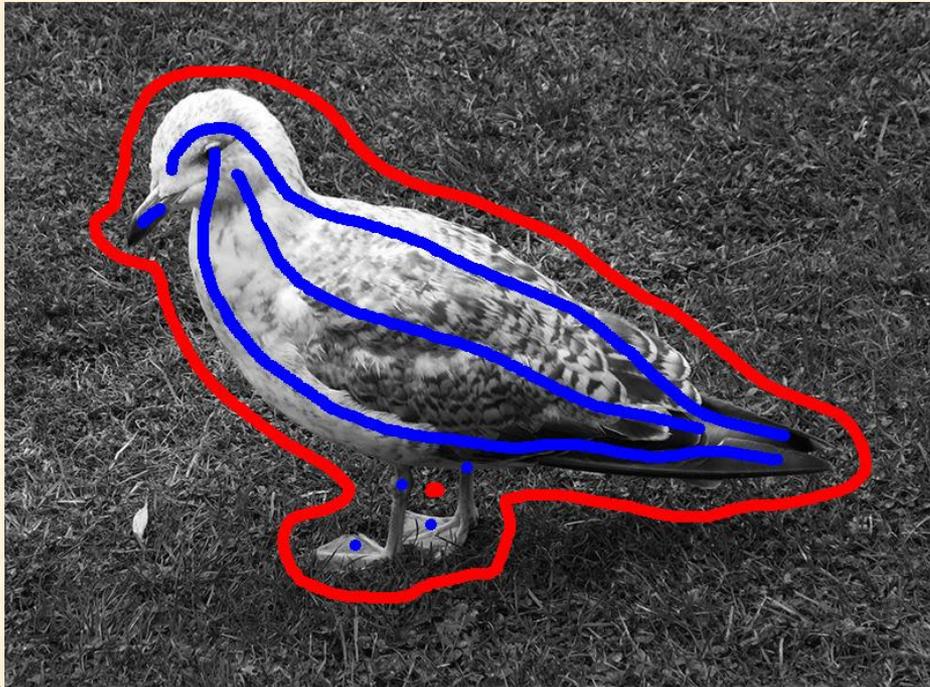
Segmentação Interativa de Imagens usando Propagação de Rótulos em Redes Complexas

- Primeiro passo com rede complexa montada usando grafos ponderado e direcionado
 - Conexão com k -vizinhos mais próximos
 - Forma redes de pequeno mundo para propagação rápida
- Segundo passo com rede regular para ajuste fino
- Propagação direta, sem partículas
 - Nós não rotulados “puxam” rótulo dos vizinhos (rotulados ou não)

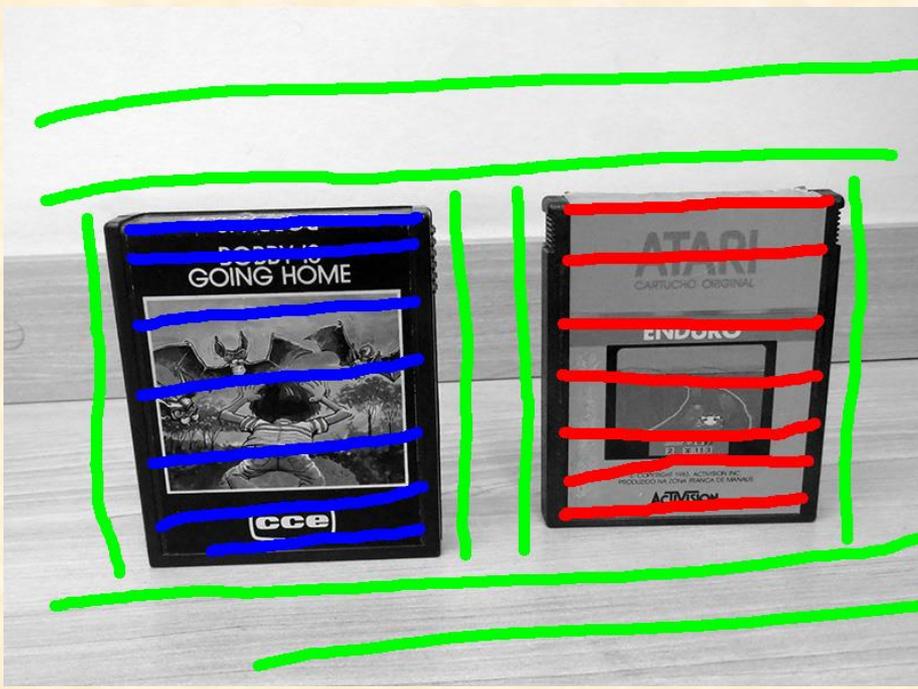
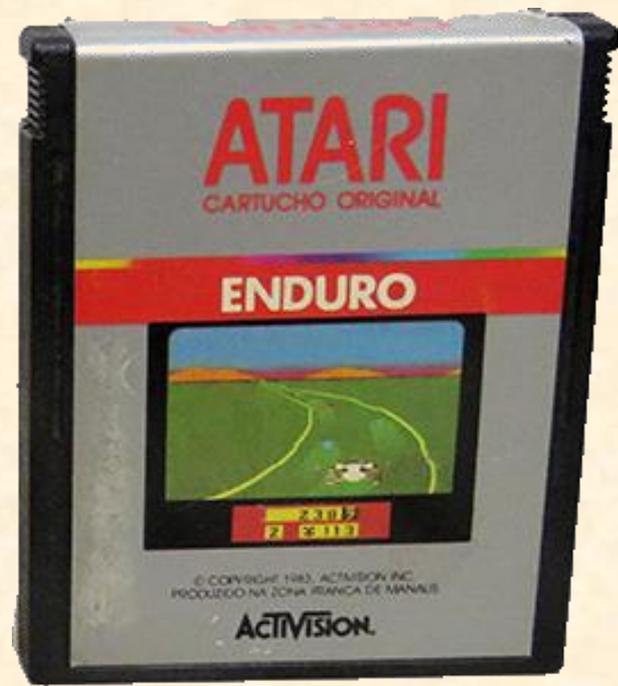


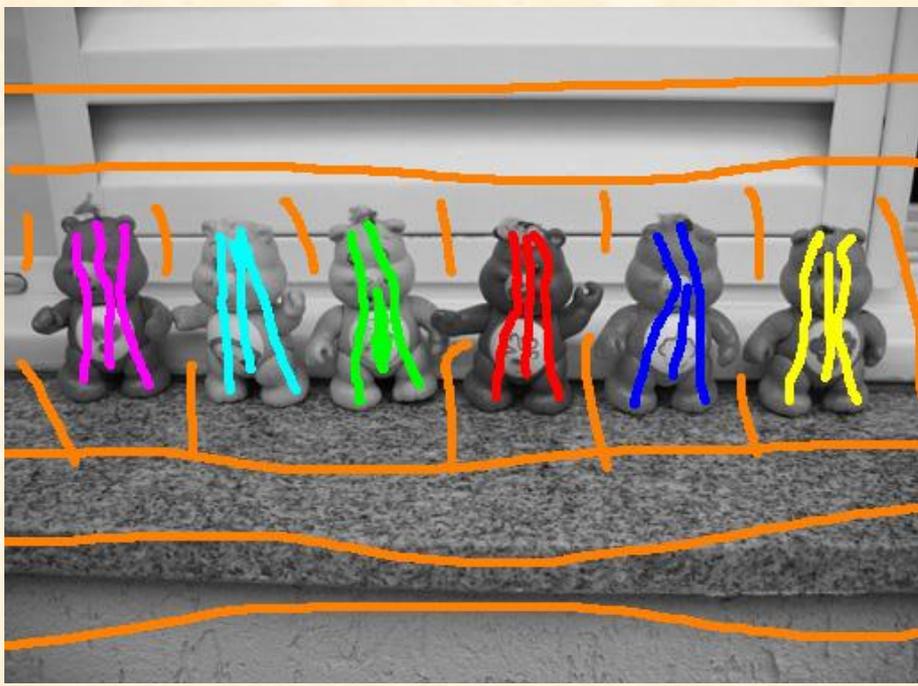












Outras extensões do Modelo de Competição e Cooperação entre Partículas

• Aprendizado Ativo e Semi-Supervisionado

- BREVE, Fabricio Aparecido . Active Semi-Supervised Learning using Particle Competition and Cooperation in Networks. In: The 2013 International Joint Conference on Neural Networks (IJCNN), 2013, Dallas, Texas. The 2013 International Joint Conference on Neural Networks (IJCNN), 2013. p. 1737-1742.
<http://dx.doi.org/10.1109/IJCNN.2013.6706949>
- BREVE, Fabricio Aparecido. Combined Active and Semi-Supervised Learning using Particle Walking Temporal Dynamics In: 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence, 2013, Ipojuca - Pernambuco. Proceedings of the 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence, 2013.
<http://dx.doi.org/10.1109/BRICS-CCI-CBIC.2013.14>
- BREVE, Fabricio Aparecido. Query Rules Study on Active Semi-Supervised Learning using Particle Competition and Cooperation. In: Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2014, São Carlos. Anais do Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2014.

• Classificação Semi-Supervisionada de Fluxos de Dados

- BREVE, Fabricio Aparecido ; ZHAO, Liang . Particle Competition and Cooperation in Networks for Semi-Supervised Learning with Concept Drift. In: IEEE World Congress on Computational Intelligence (IEEE WCCI 2012) - International Joint Conference on Neural Networks (IJCNN 2012), 2012, Brisbane, Australia. Proceedings of 2012 World Congress on Computational Intelligence (WCCI 2012), 2012. p. 1803-1808.
<http://dx.doi.org/10.1109/IJCNN.2012.6252617>
- BREVE, Fabricio Aparecido ; ZHAO, Liang . Semi-Supervised Learning with Concept Drift using Particle Dynamics applied to Network Intrusion Detection Data. In: 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence, 2013, Ipojuca - Pernambuco. Proceedings of the 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence, 2013.
<http://dx.doi.org/10.1109/BRICS-CCI-CBIC.2013.63>

Conclusões

Conclusões

- A estratégia de competição e cooperação entre partículas em redes:
 - É diferente de todas as técnicas tradicionais de aprendizado semi-supervisionado
 - Apresenta bom desempenho de classificação, comparável ao estado da arte
 - Porém com complexidade computacional inferior a de muitos outros modelos baseados em grafos
 - E abordagem fundamentalmente diferente das demais

Conclusões

- A estratégia de competição e cooperação entre partículas também pode ser naturalmente estendida para tratar vários outros problemas de aprendizado de máquina:
 1. Bastante eficaz na detecção de nós sobrepostos, oferecendo novas possibilidades de tratamento de dados que apresentem tais estruturas;
 2. Oferece a possibilidade de detectar outliers e evitar a propagação de erros vinda dos mesmos, superando o desempenho de classificação de outros algoritmos;
 3. Tem se mostrado bastante promissora na tarefa de segmentação de imagens, obtendo resultados comparáveis aos de métodos do estado da arte.

Impacto do modelo de Partículas

- Google Acadêmico (até 05/11/2019)
 - 82 citações do artigo original
 - 238 citações do artigo original e suas extensões
- Utilizado em 55 artigos publicados (até 05/11/2019)
 - 5 Artigos Completos em Periódicos Nacionais e Internacionais
 - *IEEE Transactions on Knowledge and Data Engineering*
 - *Neurocomputing*
 - *Soft Computing*
 - 15 Artigos Completos em Conferências Nacionais e Internacionais
 - 14 Resumos em Conferências Nacionais
 - 5 Dissertações de Mestrado
 - 5 Trabalhos de Conclusão de Curso

Aprendizado Semi-Supervisionado usando Competição e Cooperação entre Partículas em Redes Complexas

Fabricio Breve
UNESP

<http://www.fabriciobreve.com>