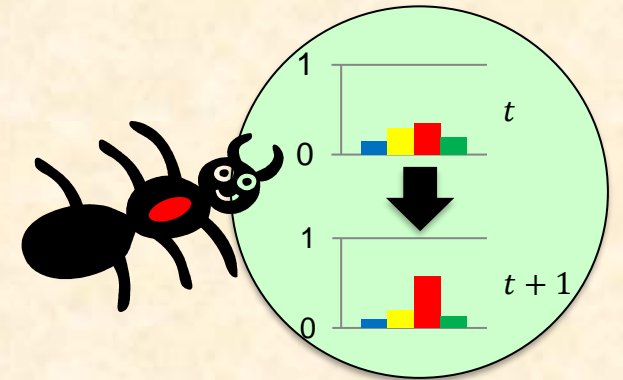


Competição e Cooperação entre Partículas em Grafos

Fabricio Breve

www.fabriciobreve.com



Agenda

- Introdução
 - Aprendizado de Máquina
 - Aprendizado Semi-Supervisionado
 - Modelos Baseados em Grafos
- Competição e Cooperação entre Partículas em Grafos
 - Motivações
 - Descrição do Modelo
 - Resultados
- Extensões do Modelo
 - Detecção de Comunidades Sobrepostas
 - Aprendizado Semi-Supervisionado com Dados Imperfeitos
 - Classificação Semi-Supervisionada de Fluxos de Dados
 - Aprendizado Ativo e Semi-Supervisionado
 - Segmentação Interativa de Imagens
- Novas Aplicações
- 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 de 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.



SPAM




Não-SPAM

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.






Supervised Learning

Unsupervised Learning


<https://medium.com/analytics-vidhya/machine-learning-landscape-for-beginners-19aeb5dbd466>

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.



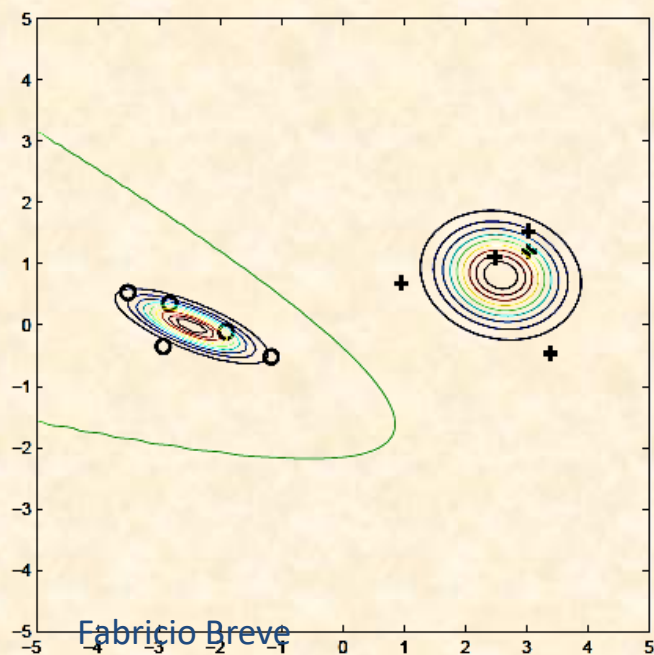
- Zhu, X. *Semi-Supervised Learning Literature Survey*. Technical Report 1530, Computer Sciences, University of Wisconsin-Madison, 2005.
- Chapelle, O., Schölkopf, B., & Zien, A., Eds. *Semi-Supervised Learning. Adaptive Computation and Machine Learning*. Cambridge, MA: The MIT Press, 2006.
- Abney, 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.

Algumas Classes de Algoritmos de Aprendizado Semi-Supervisionado


- Auto Treinamento
- Modelos Generativos
- Separação de Baixa Densidade
- **Métodos Baseados em Grafos**



- X. Zhu, *Semi-supervised learning literature survey*, Computer Sciences, University of Wisconsin-Madison, Tech. Rep. 1530, 2005.
- O. Chapelle, B. Schölkopf, and A. Zien, Eds., *Semi-Supervised Learning*, ser. Adaptive Computation and Machine Learning. Cambridge, MA: The MIT Press, 2006.

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.



Métodos Baseados em Grafos

- Seja um grafo $G = (V, E)$, com $V = \{v_1, v_2, \dots, v_n\}$, onde cada nó v_i corresponde a uma amostra x_i
- Uma matriz de adjacência W define quais nós da rede estão interconectados, ou seja, ele identifica as arestas em E

$$W_{ij} = \begin{cases} W_{ij}(e) & \text{se } i \text{ e } j \text{ são vizinhos} \\ 0 & \text{se } i \text{ e } j \text{ não são vizinhos} \end{cases}$$

$w_{ij}(e)$ pode ser um número real que mede a similaridade entre i e j (por exemplo)

Métodos de Construção do Grafo

- Uma matriz de peso típica é dada pelo *kernel* Gaussiano de largura σ :

$$W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$$

- Também podemos considerar apenas os k -vizinhos mais próximos.

- Exemplo:

- $W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$ se x_i está entre os k -vizinhos mais próximos de x_j ou vice-versa.

- $W_{ij} = 0$ caso contrário.

- Outra alternativa é criar uma rede de k -vizinhos sem pesos:

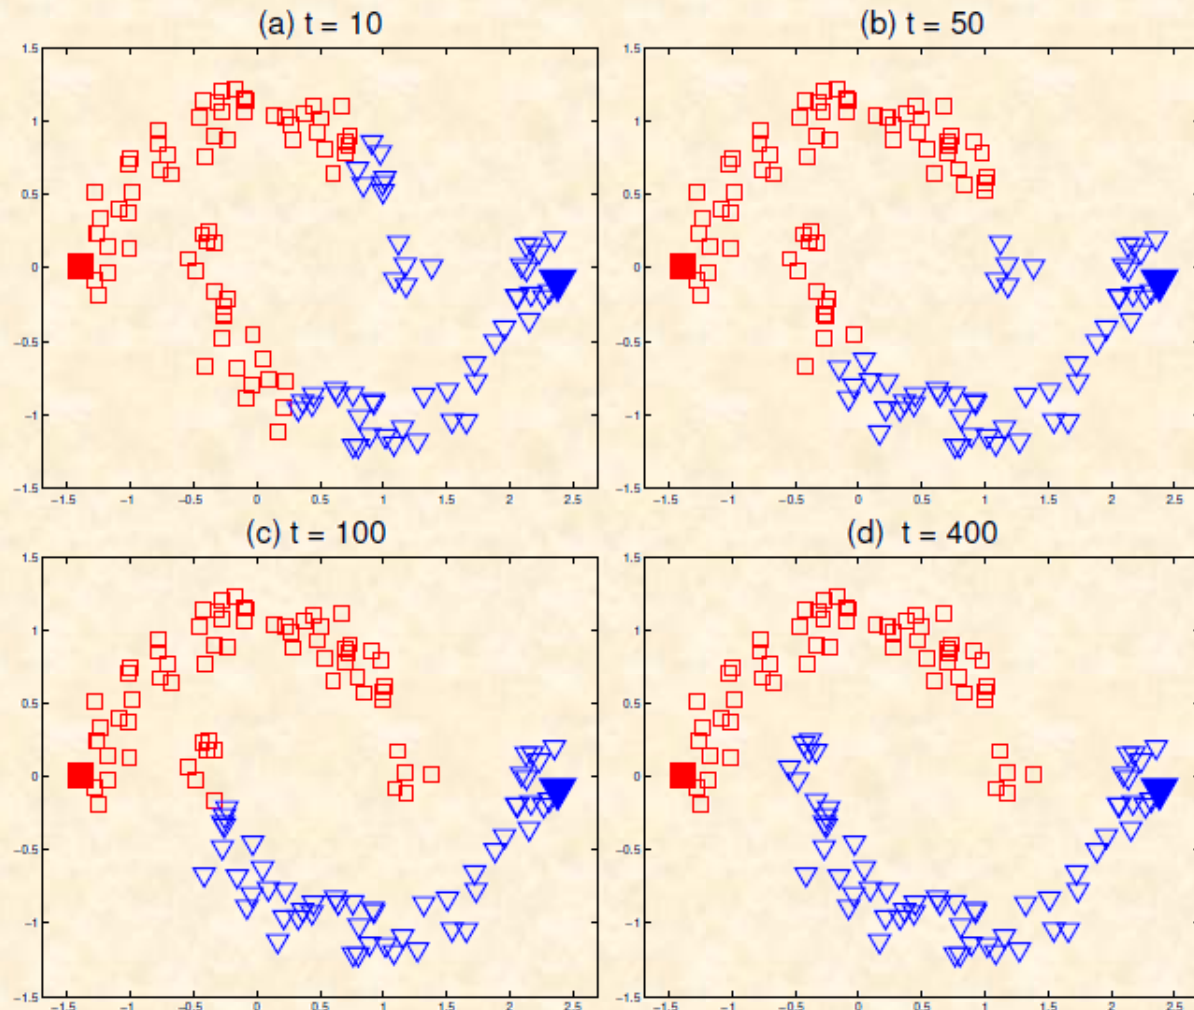
- $W_{ij} = 1$ se x_i está entre os k -vizinhos mais próximos de x_j ou vice-versa.

- $W_{ij} = 0$ caso contrário.

Propagando rótulos pelo grafo

- Nós rotulados iniciam com seus respectivos rótulos (1 ou -1).
 - Nós não rotulados iniciam com 0.
 - Nós propagam seus rótulos repetidamente até convergência.
 - Exemplo:
 - A cada passo um nó i pode receber a contribuição de seus vizinhos j , ponderados pelo peso normalizado da aresta (i, j) , e uma pequena contribuição adicional de seu valor inicial
-
- X. Zhu and Z. Ghahramani, *Learning from labeled and unlabeled data with label propagation*, Carnegie Mellon University, Pittsburgh, Tech. Rep. CMU-CALD-02-107, 2002.
 - D. Zhou, O. Bousquet, T. N. Lal, J. Weston, and B. Schölkopf, **Learning with local and global consistency**, in *Advances in Neural Information Processing Systems*, vol. 16. MIT Press, 2004, pp. 321–328.

Propagando rótulos pelo grafo



Classificação de padrão com duas luas dado pelo modelo de Zhou et. al. (2004). O processo de convergência do algoritmo com t crescendo de 1 a 400 é mostrado de (a) até (d). Note que as informações de rótulos iniciais são difundidas ao longo das luas.

D. Zhou, O. Bousquet, T. N. Lal, J. Weston, and B. Schölkopf, **Learning with local and global consistency**, in *Advances in Neural Information Processing Systems*, vol. 16. MIT Press, 2004, pp. 321–328.

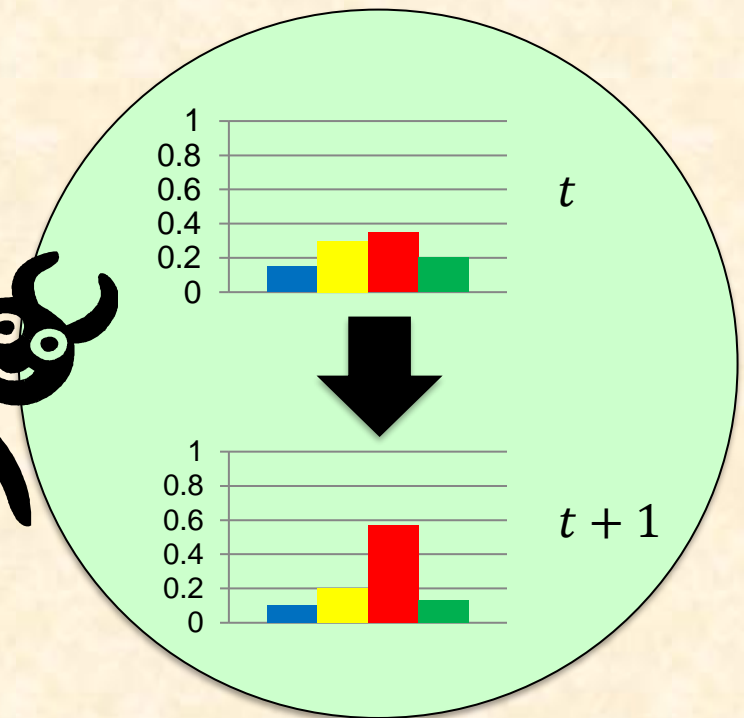

Competição e Cooperação entre Partículas em Grafos

Motivação

Descrição do Modelo

Resultados

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>



Motivação


- Por que criar um novo método de aprendizado semi-supervisionado baseado em grafos?
 - A maioria dos métodos equivale a um *framework* de regularização, diferindo apenas na escolha da função de perda e do regularizador.
 - A maioria dos métodos tem ordem de complexidade computacional cúbica ($O(n^3)$), devido à propagação dos rótulos de forma global, tornando sua aplicação limitada a conjuntos de dados pequenos ou médios.

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


Origem: Modelo de Competição de Partículas

- Aplicado em Agrupamento de Dados (Aprendizado Não Supervisionado).
- Cada partícula representa um grupo (*cluster*).
- Partículas caminham na rede e competem com as outras de forma que cada uma tenta possuir a maior quantidade de nós possível.
- Cada partícula tenta evitar que outras partículas invadam seu território.
- Finalmente, cada partícula é confinada dentro de uma comunidade na rede.

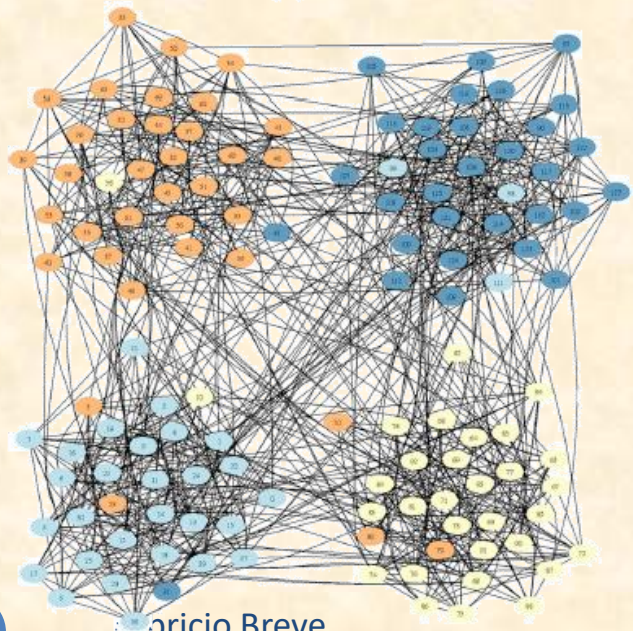
M. G. Quiles, L. Zhao, R. L. Alonso, and R. A. F. Romero, **Particle competition for complex network community detection**, *Chaos*, vol. 18, no. 3, p. 033107, 2008.




(a)



(b)



(c)




(d)

Ilustração do processo de detecção de comunidade pela competição de partículas. O número total de nós é $N = 128$, o número de comunidades é $M = 4$.

- a) Configuração inicial. Quatro partículas representadas por amarelo, ciano, laranja e azul, são colocadas aleatoriamente na rede. Vermelho representa nós livres.
- b) Um *snapshot* da iteração 250.
- c) Um *snapshot* da iteração 3500.
- d) Um *snapshot* da iteração 7000.


Competição e Cooperação entre Partículas em Grafos

- Aplicação em Classificação Semi-Supervisionada.
- 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.



Configuração Inicial dos Nós

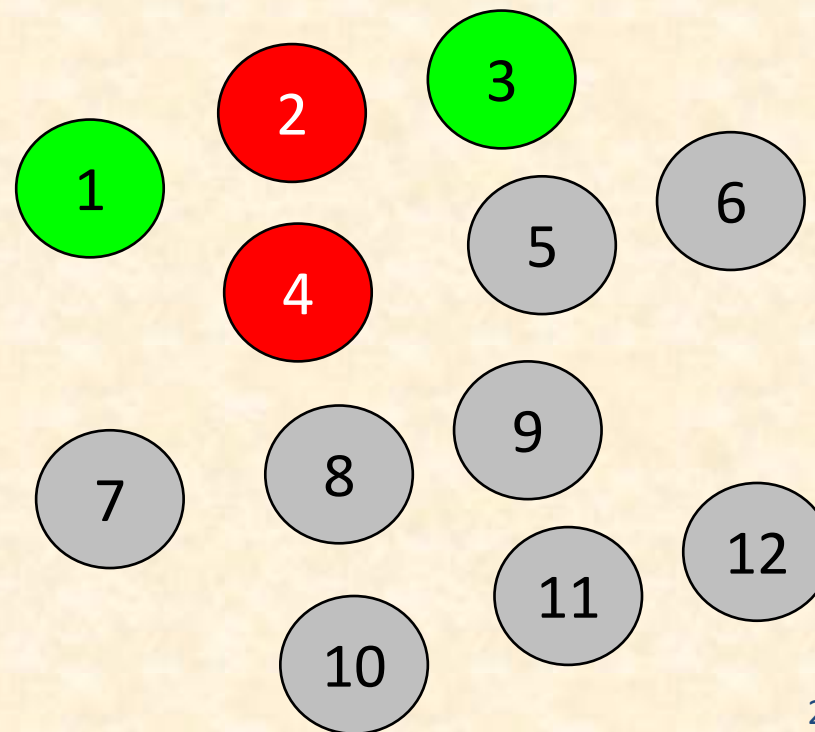
- Transforma-se o conjunto de dados em uma rede não direcionada sem peso.
- Para cada item de dado é gerado um nó na rede.
- As arestas podem ser geradas de várias formas:
 - Cada nó é conectado aos vizinhos cuja distância é menor que um limiar σ
 - Cada nó é conectado aos seus k vizinhos mais próximos.



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...

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	?

Dados normalizados: média 0, desvio padrão 1


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	ENEM norm. (x)	Média norm. (y)	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	?



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

	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	

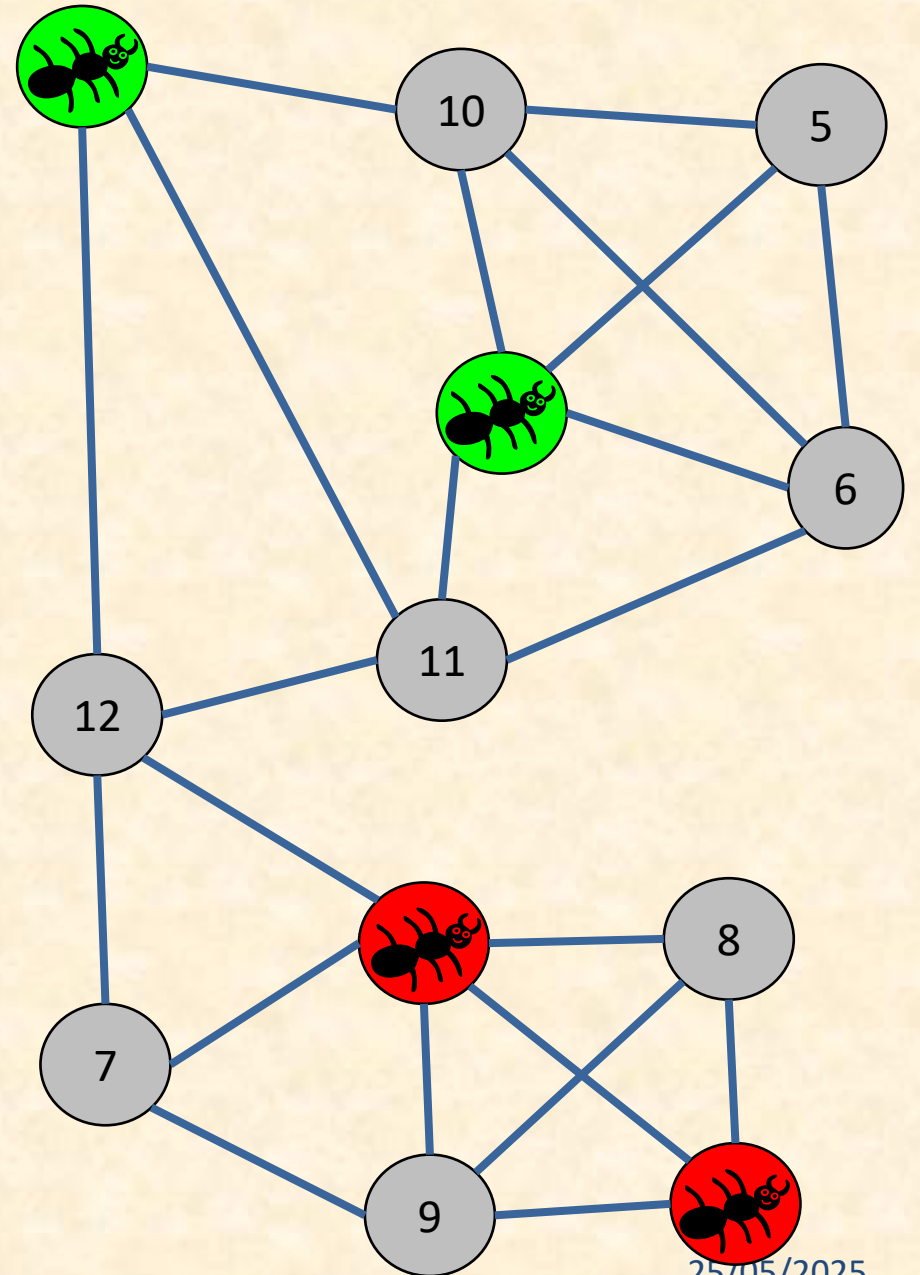


25/05/2025

Nota: existem formas mais eficientes de calcular os k-vizinhos que calcular a distância entre todos os pares de nós. Por exemplo: usando k-d trees (O(n log n)).

Configuração Inicial das Partículas

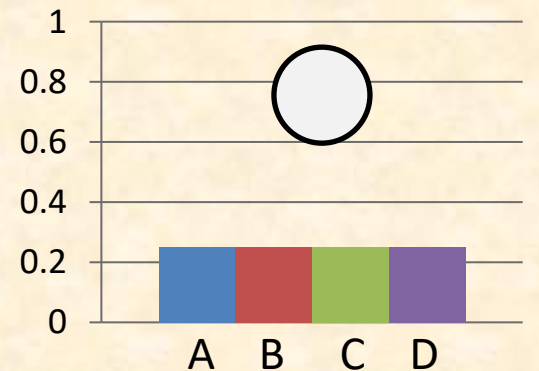
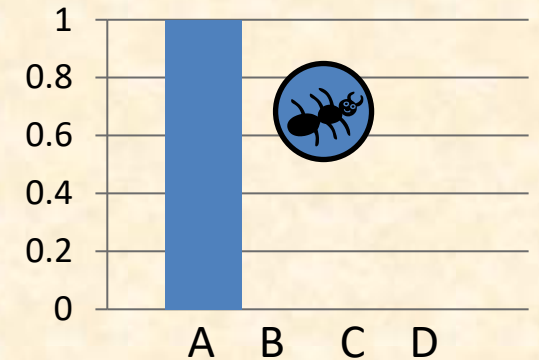
- Uma partícula é gerada para cada nó rotulado na rede.
 - Este nó será o *nó casa* da partícula correspondente.
- A posição inicial de cada partícula é ajustada para seu respectivo nó casa.
- Partículas com o mesmo rótulo jogam para o mesmo time.



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.

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



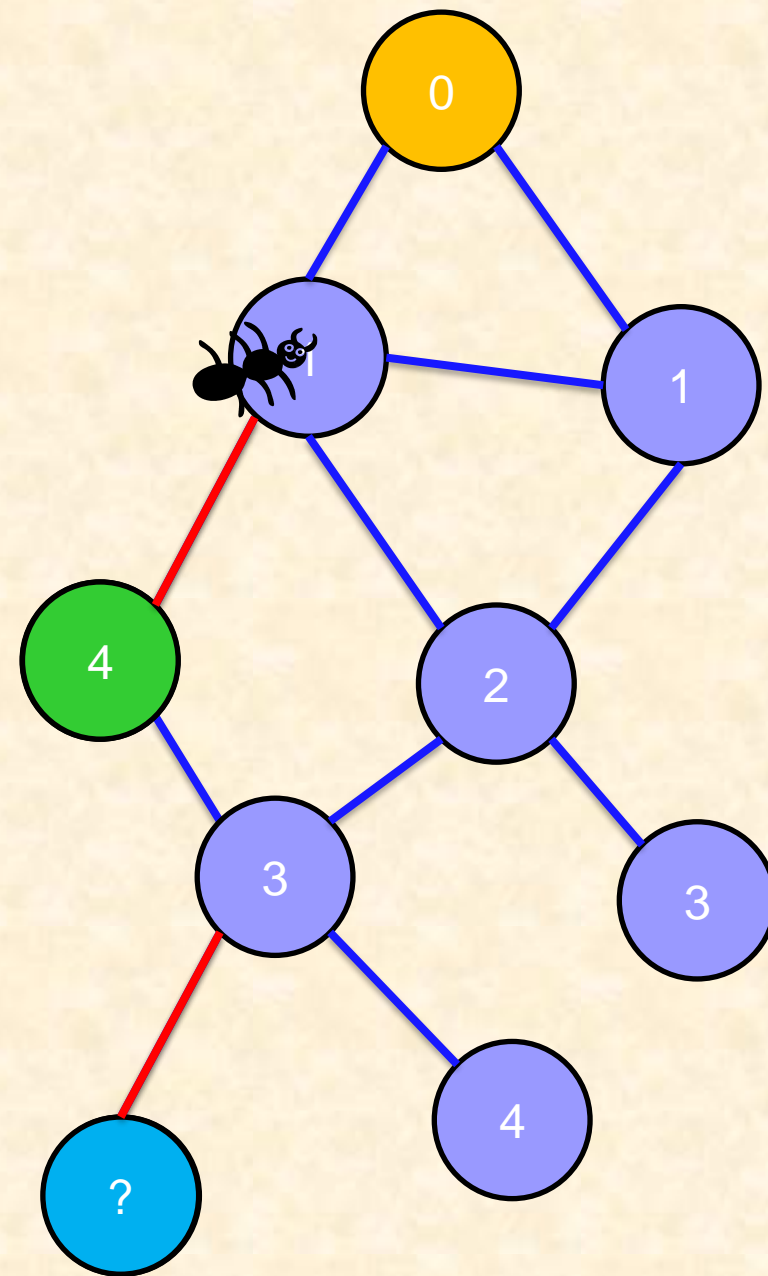


Tabela de Distância

- Mantém a partícula informada da distância de qualquer nó para o 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 vizinho para visitar sem preocupação com os níveis 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

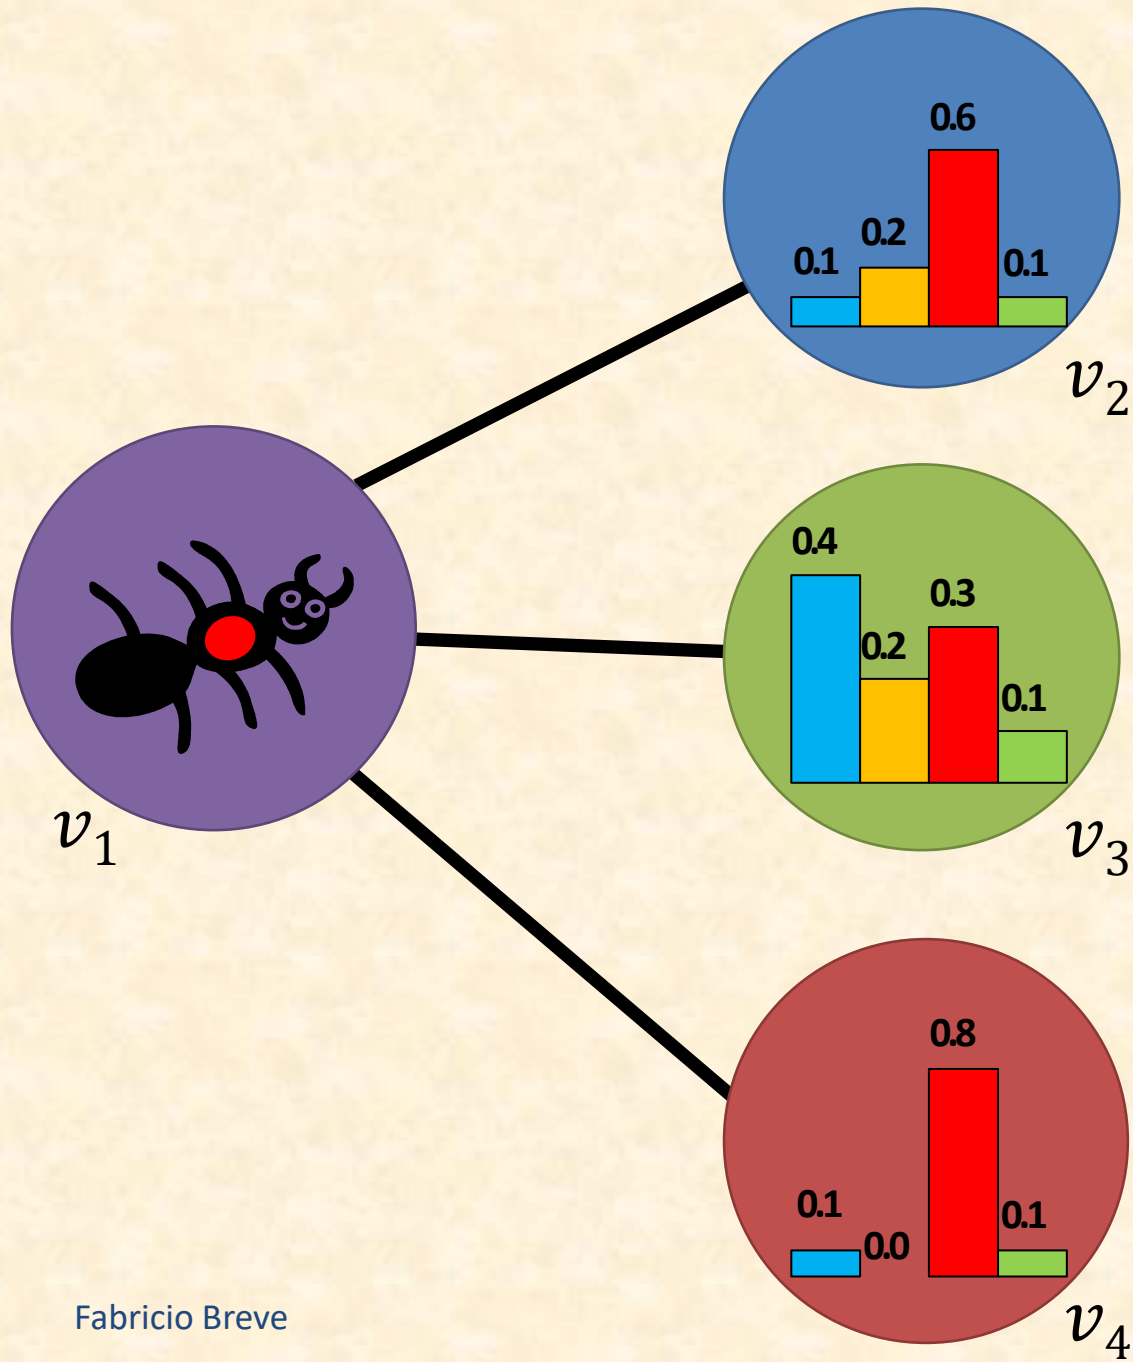
- Caminhada Gulosa:

- 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 pela 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

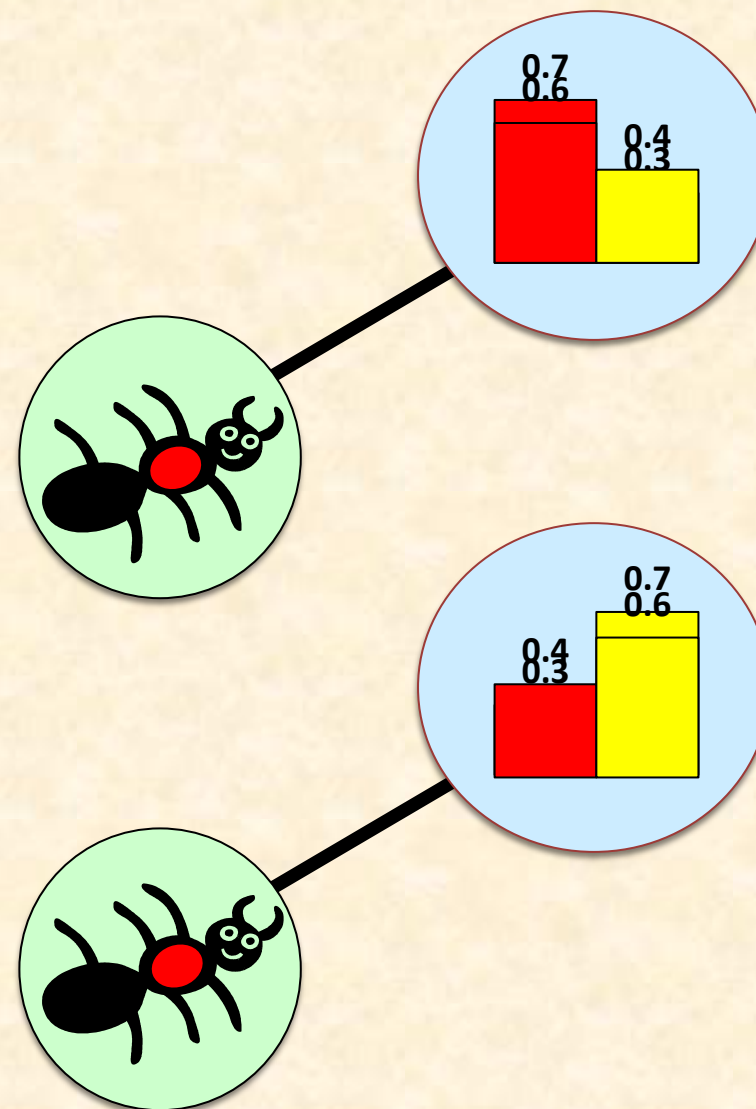


Probabilidades no Movimento Aleatório



Choques

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



Algoritmo

Construir o grafo;

Configurar os níveis de domínio de todos os nós;

Configurar a posição inicial de cada partícula e seu correspondente nó-casa;

Configurar a força de cada partícula e sua respectiva tabela de 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.













Configuração Inicial ($t = 0$)















Após 10 iterações... ($t = 10$)















Após 50 iterações... ($t = 50$)



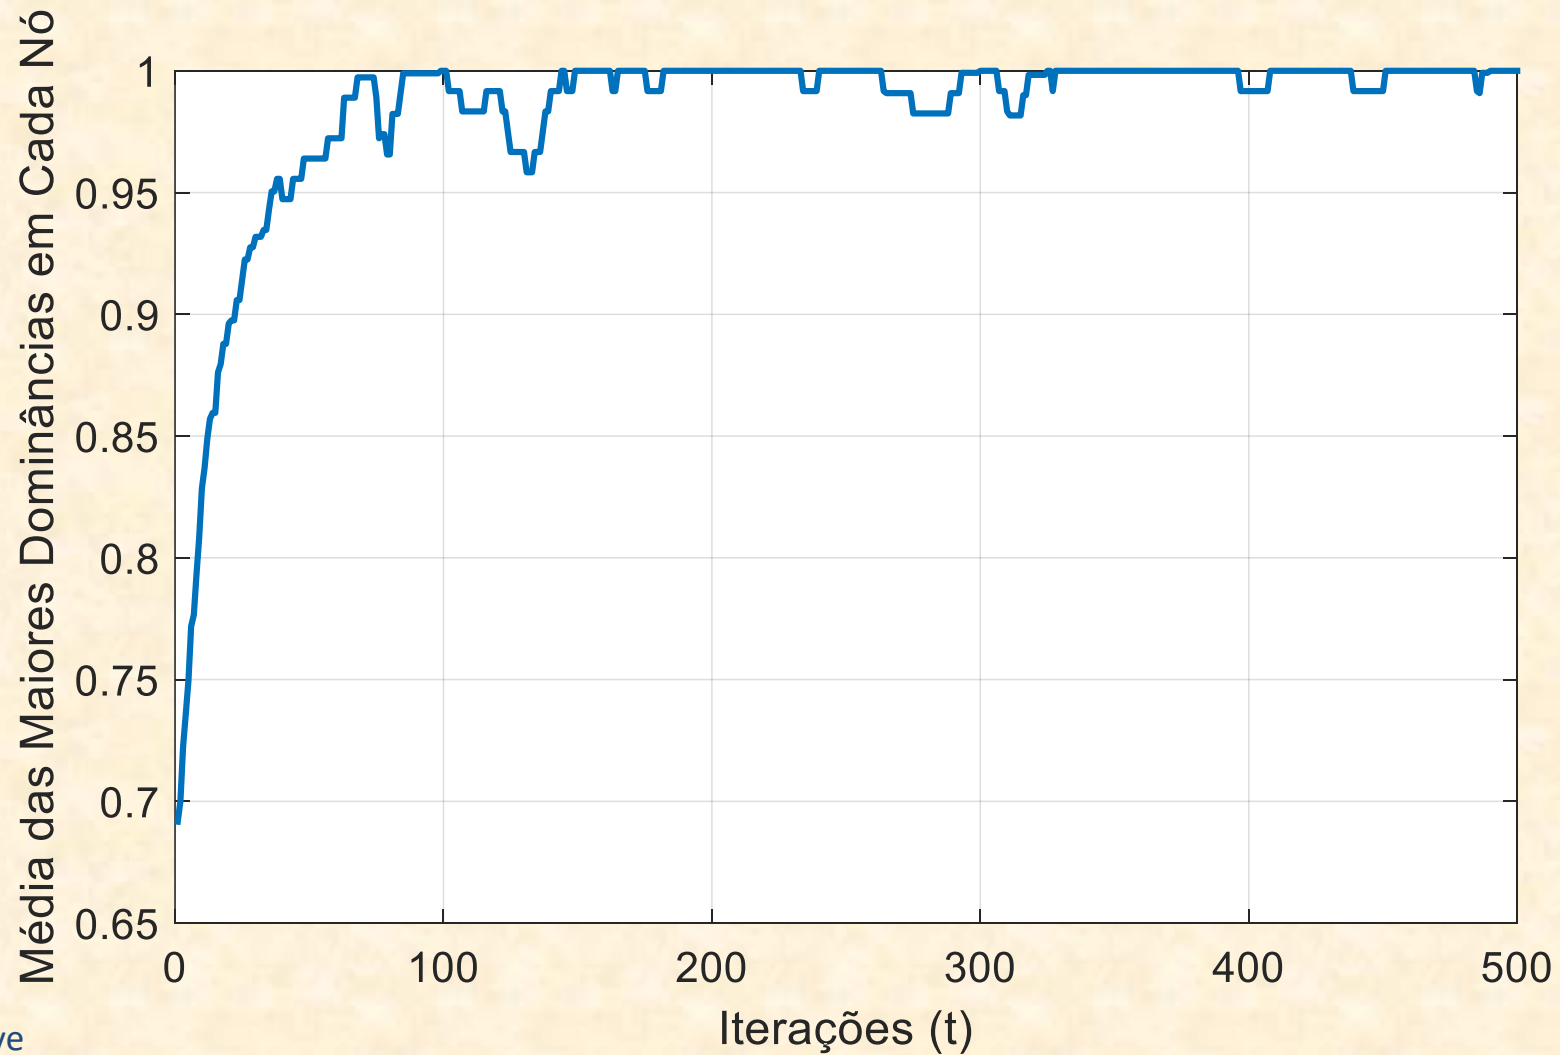
Após 150 iterações... ($t = 150$)



Após 250 iterações... ($t = 250$)




Critério de Parada




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” cada nó com a classe da partícula que o dominou...




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.



Tabelas de Distância (final das iterações)

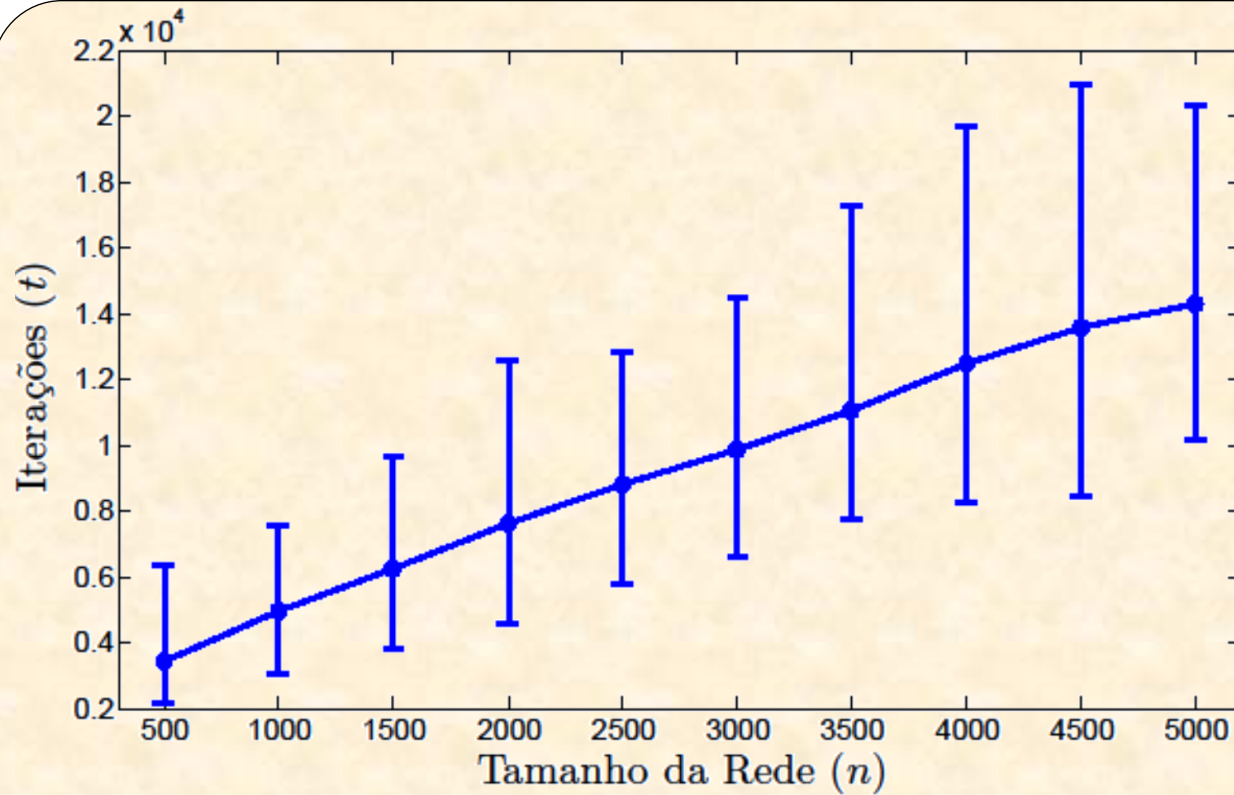
	Part. 1	Part. 2	Part. 3	Part. 4
Nó 1	0	3	2	2
Nó 2	11	0	11	1
Nó 3	2	11	0	11
Nó 4	2	1	4	0
Nó 5	2	11	1	11
Nó 6	2	11	1	11
Nó 7	2	2	4	1
Nó 8	11	1	11	1
Nó 9	11	1	11	1
Nó 10	1	11	1	11
Nó 11	1	11	1	11
Nó 12	1	2	3	1



Análise de Complexidade

Análise de complexidade do método proposto em rede com média mistura:

- (a) Número de iterações
- (b) Tempo necessário para a convergência da média dos maiores níveis de domínio dos nós com tamanho de rede crescente.




$$l = 50$$

$$\langle k \rangle = 25$$

$$z_{out} = 5$$

$$z_{out} / \langle k \rangle = 0,2$$




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.

Análise de Complexidade

Análise de complexidade do método proposto em rede com alta mistura:

- (a) Número de iterações
- (b) Tempo necessário para a convergência da média dos maiores níveis de domínio dos nós com tamanho de rede crescente




$$l = 50$$

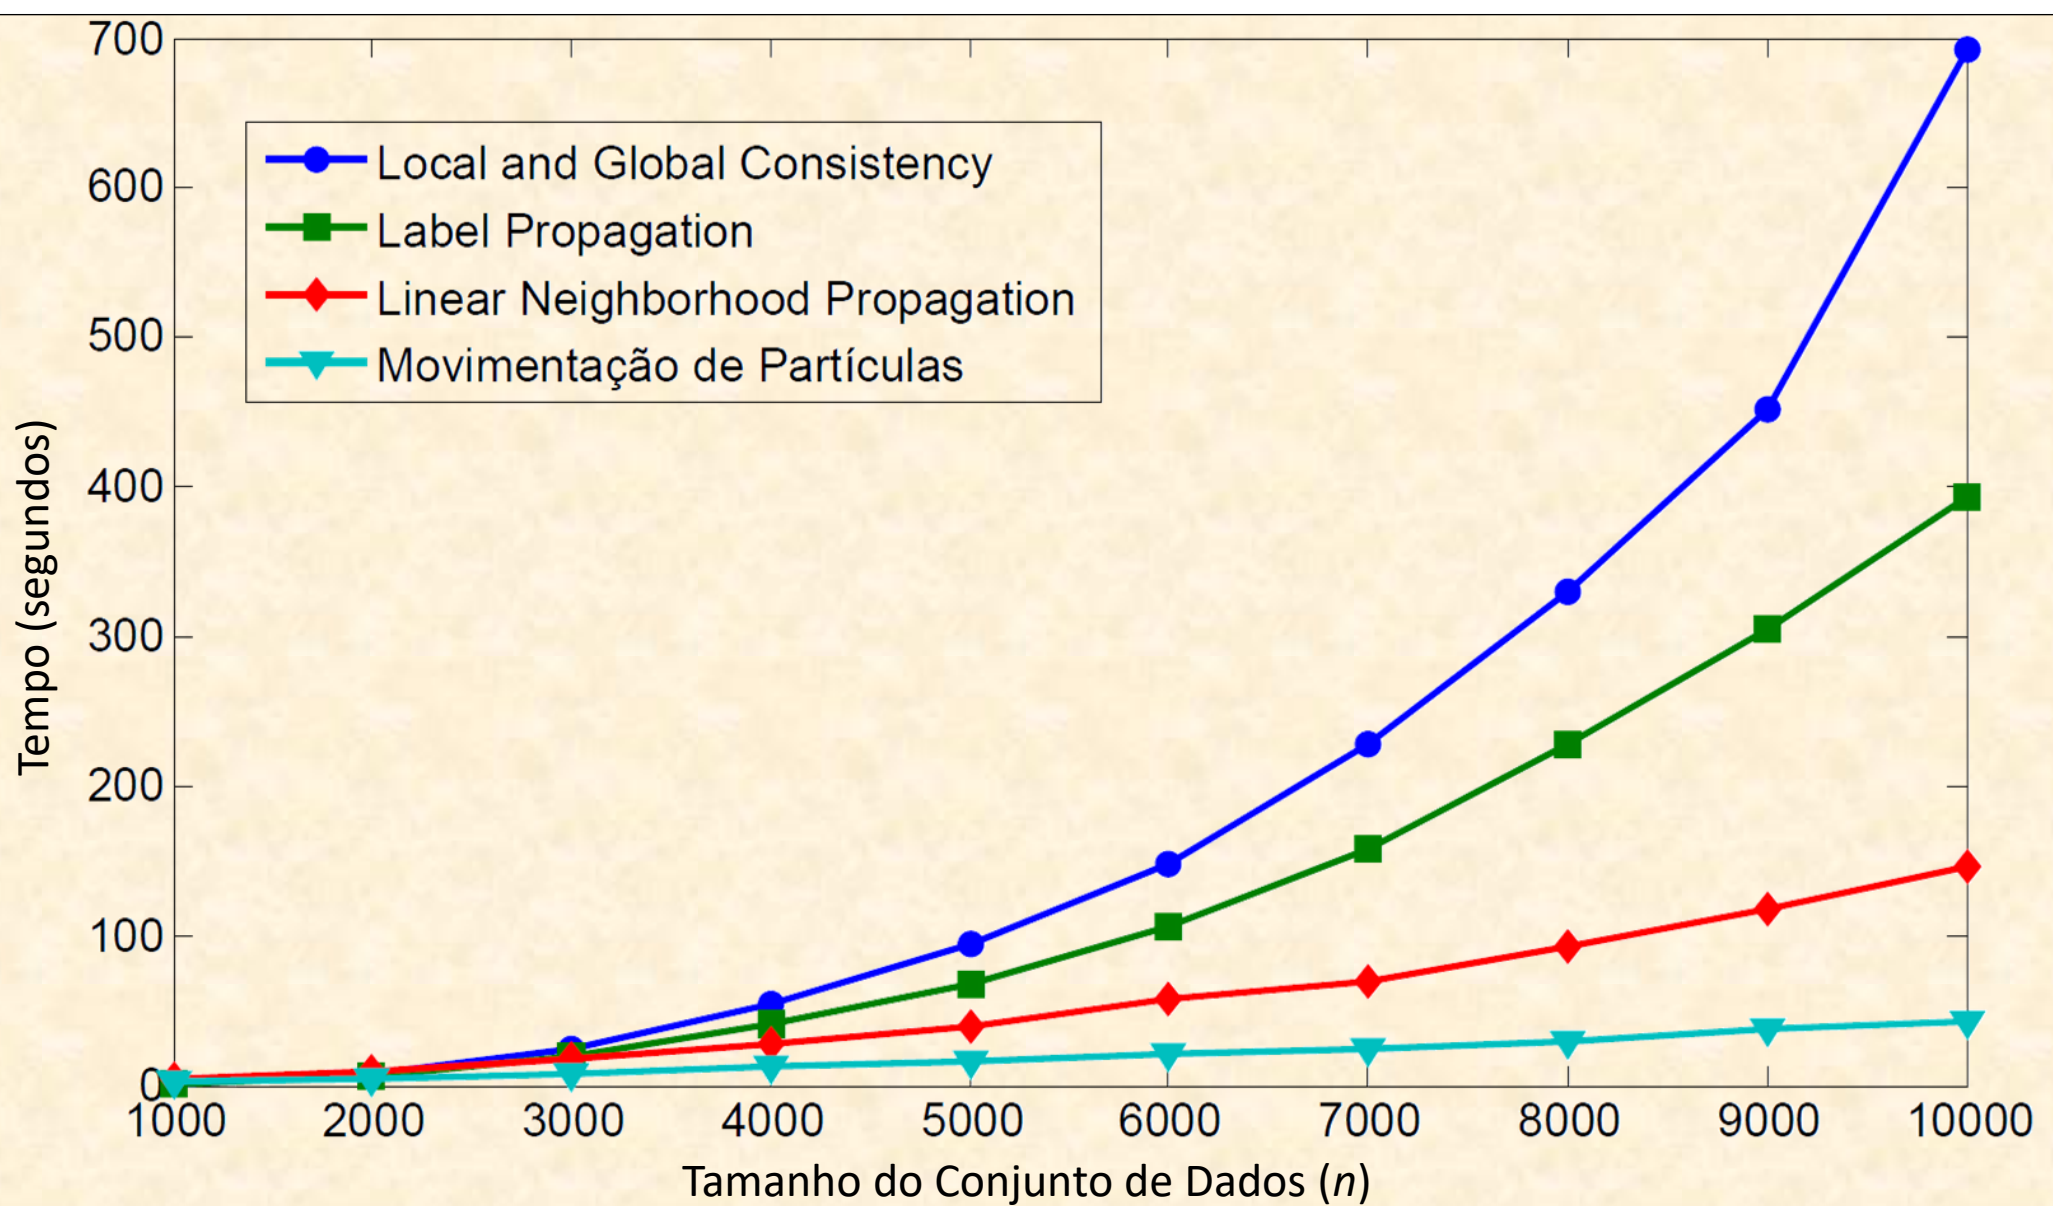
$$\langle k \rangle = 25$$

$$z_{out} = 10$$

$$z_{out} / \langle k \rangle = 0,4$$

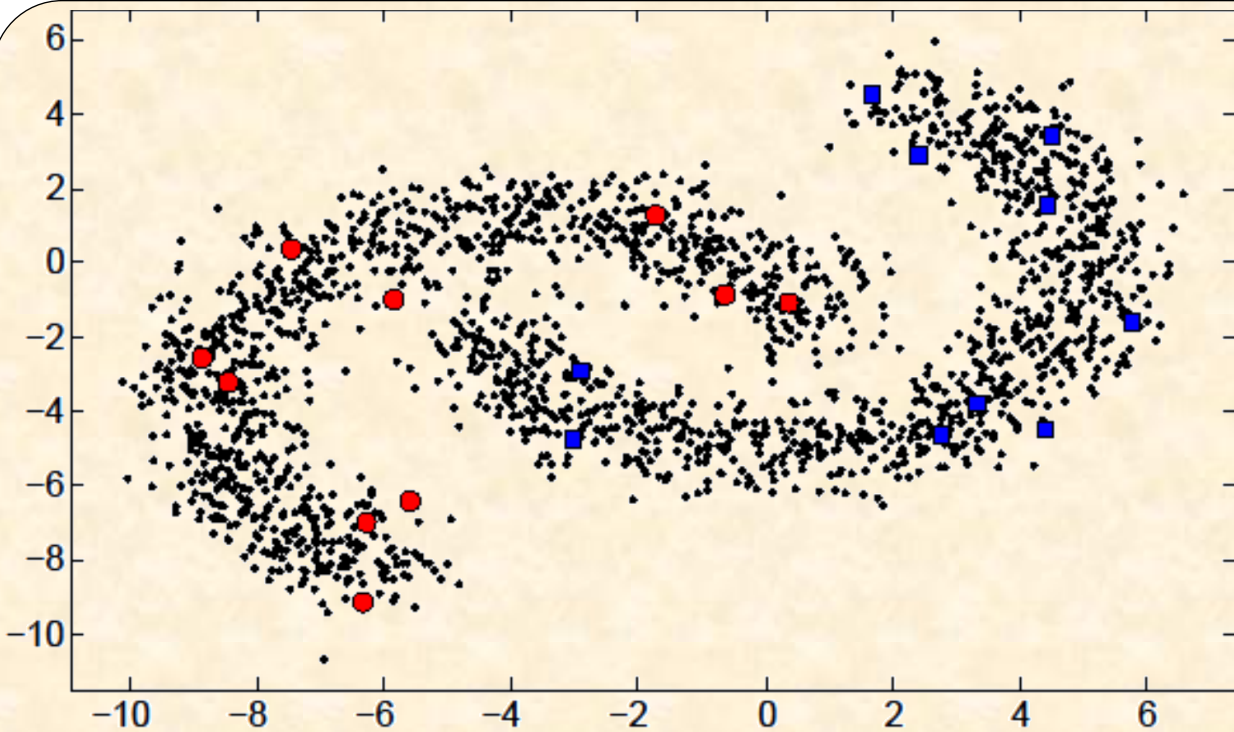


L. Danon, A. Díaz-Guilera, J. Duch, and A. Arenas, "Comparing Community Structure Identification," *J. Statistical Mechanics: Theory and Experiment*, vol. 9, p. P09008 (1-10), 2005.




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


Desempenho de Classificação




Classificação de conjunto de dados artificial com 2.000 elementos divididos igualmente em duas classes com forma de banana





Desempenho de Classificação



Classificação de conjunto de dados artificial com 1.000 elementos divididos em duas classes
Highleyman




Desempenho de Classificação




Classificação de conjunto de dados artificial com 1.200 elementos divididas em duas classes Lithuanian, com 800 e 400 elementos respectivamente

Desempenho de Classificação



Classificação de conjunto de dados artificial com 1.200 elementos igualmente divididos em três classes com distribuição Gaussiana.



	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 Aprendizagem Semi-Supervisionado com 10 pontos de dados rotulados

	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

Erros de Classificação e Tempos de Execução em Grandes Conjuntos 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 conjuntos de dados grandes


Implementação 2009 vs. 2024

- Implementação atual:
 - Mais eficiente:
 - Código em MATLAB com loop principal em C compilado (MEX).
 - Diversas melhorias no código para reduzir o tempo de processamento e o uso de memória.
 - Computadores mais rápidos:
 - **2009**: Intel Core 2 Quad modelo Q9450 e 4GB de RAM.
 - **2024**: Intel Core i9-14900K e 64GB de RAM.

Dataset – Subconjunto rotulado	Versão 2009	Versão 2024
USPS – 10%	69	5,36
USPS – 5%	76	5,04
USPS – 1%	103	4,99
COIL – 10%	23	2,14
COIL – 5%	28	1,98
COIL – 1%	33	1,99
Letter – 10%	484	25,02
Letter – 5%	497	24,41
Letter – 1%	522	29,25

Tempos de Execução em Segundos – Média de 200 execuções.

Código-Fonte



- MATLAB
 - <https://github.com/fbreve/Particle-Competition-and-Cooperation>



- Python
 - <https://github.com/fbreve/pypcc>



Extensões do Modelo de Partículas




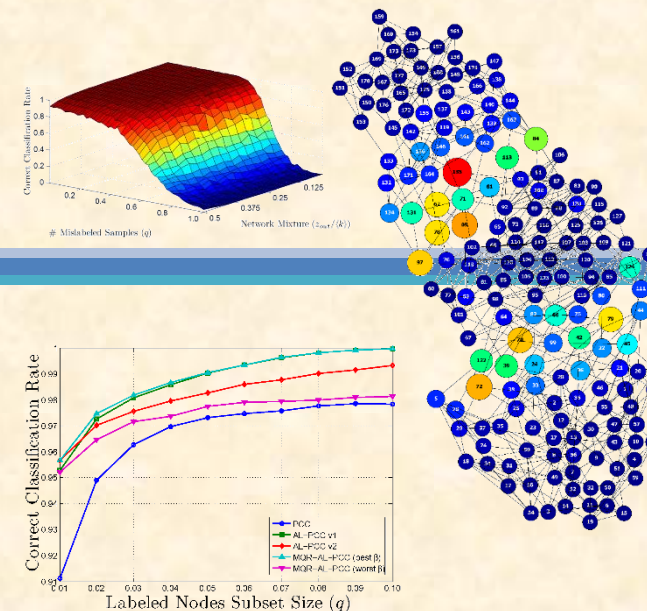
Detecção de Comunidades Sobrepostas

Aprendizado Semi-Supervisionado com Dados Imperfeitos

Classificação Semi-Supervisionada de Fluxos de Dados

Aprendizado Ativo e Semi-Supervisionado

Segmentação Interativa de Imagens




25/05/2025

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.
 - Inicia em zero para todas as classes.
 - É incrementado 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:

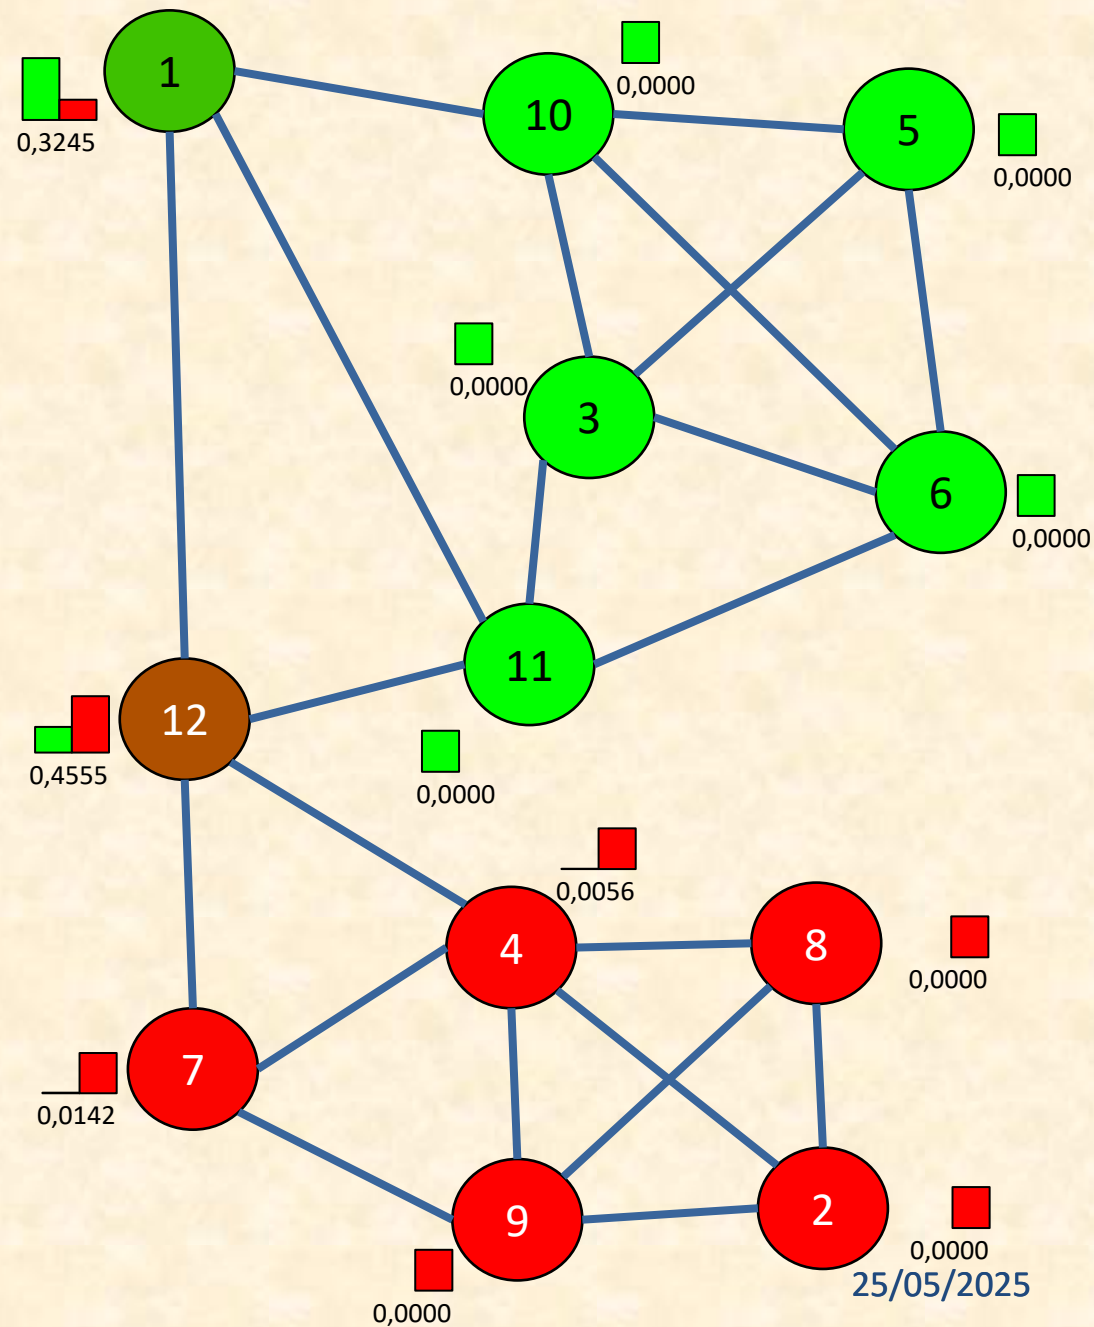
$$o_i = \frac{f_i^{\ell^{**}}}{f_i^{\ell^{*}}}$$


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

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


Voltando ao nosso exemplo dos alunos...

	Pertinência à Classe Verde	Pertinência à Classe Vermelha	Nível de Sobreposição
Nó 1	0,7550	0,2450	0,3245
Nó 2	0,0000	1,0000	0,0000
Nó 3	1,0000	0,0000	0,0000
Nó 4	0,0056	0,9944	0,0056
Nó 5	1,0000	0,0000	0,0000
Nó 6	1,0000	0,0000	0,0000
Nó 7	0,0140	0,9860	0,0142
Nó 8	0,0000	1,0000	0,0000
Nó 9	0,0000	1,0000	0,0000
Nó 10	1,0000	0,0000	0,0000
Nó 11	1,0000	0,0000	0,0000
Nó 12	0,3130	0,6870	0,4555






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.

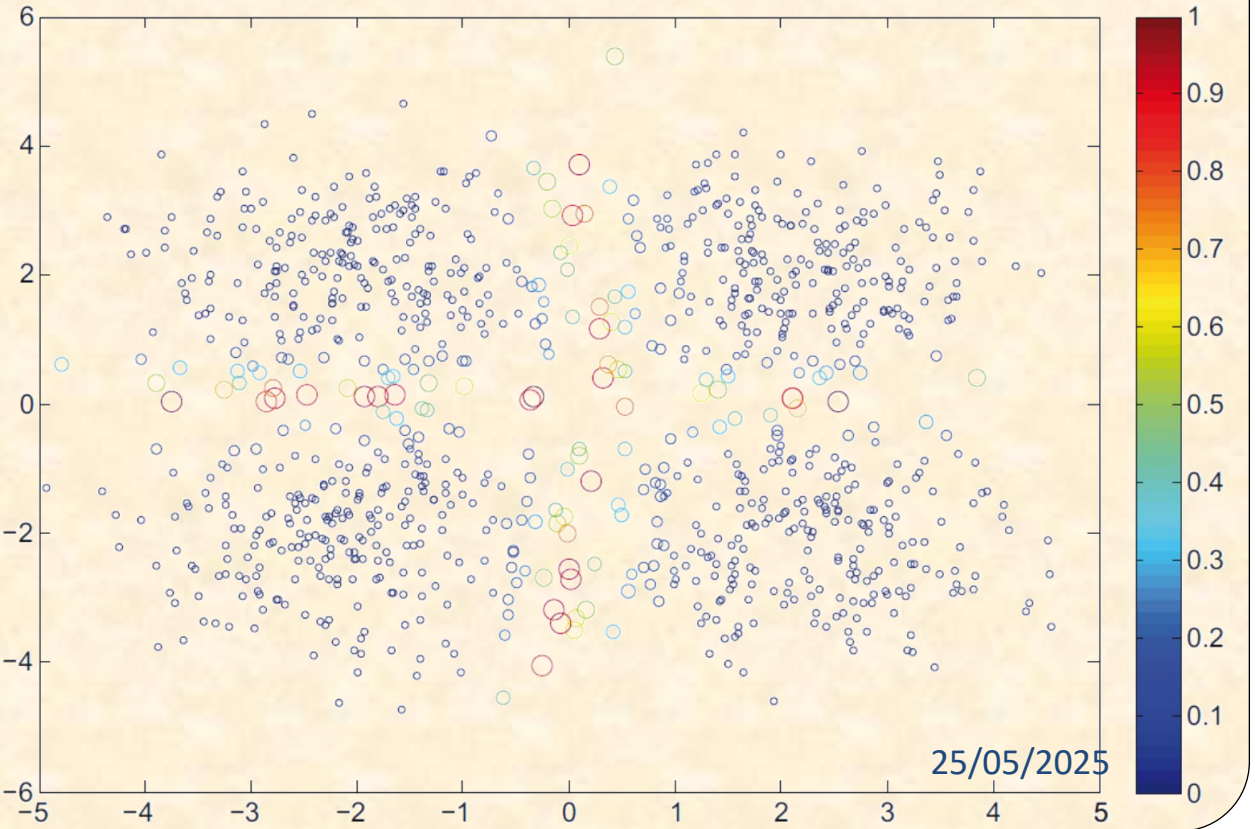


Classificação nebulosa de classes em forma de banana geradas com diferentes parâmetros de variância: (a) $s = 0.6$ (b) $s = 0.8$ (c) $s = 1.0$. Tamanho e cor dos nós representam seu respectivo índice de sobreposição.


Desempenho de Classificação Nebulosa



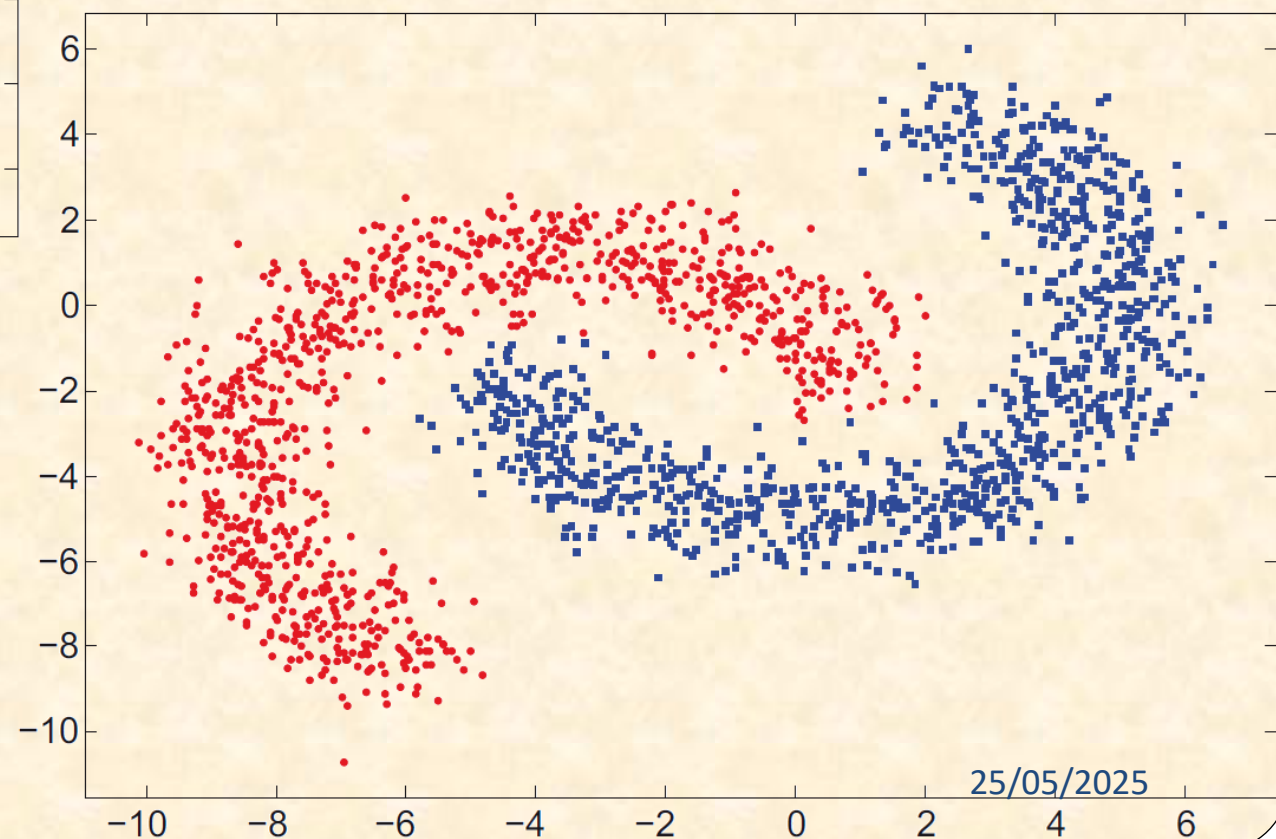
Classificação de dados com distribuição Gaussiana. (a) conjunto de dados com 1.000 elementos divididos em quatro classes, 20 amostras são rotuladas, 5 de cada classe (quadrados, triângulos, losangos, e estrelas). (b) tamanhos e cores dos nós representam o índice de sobreposição calculado pelo método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



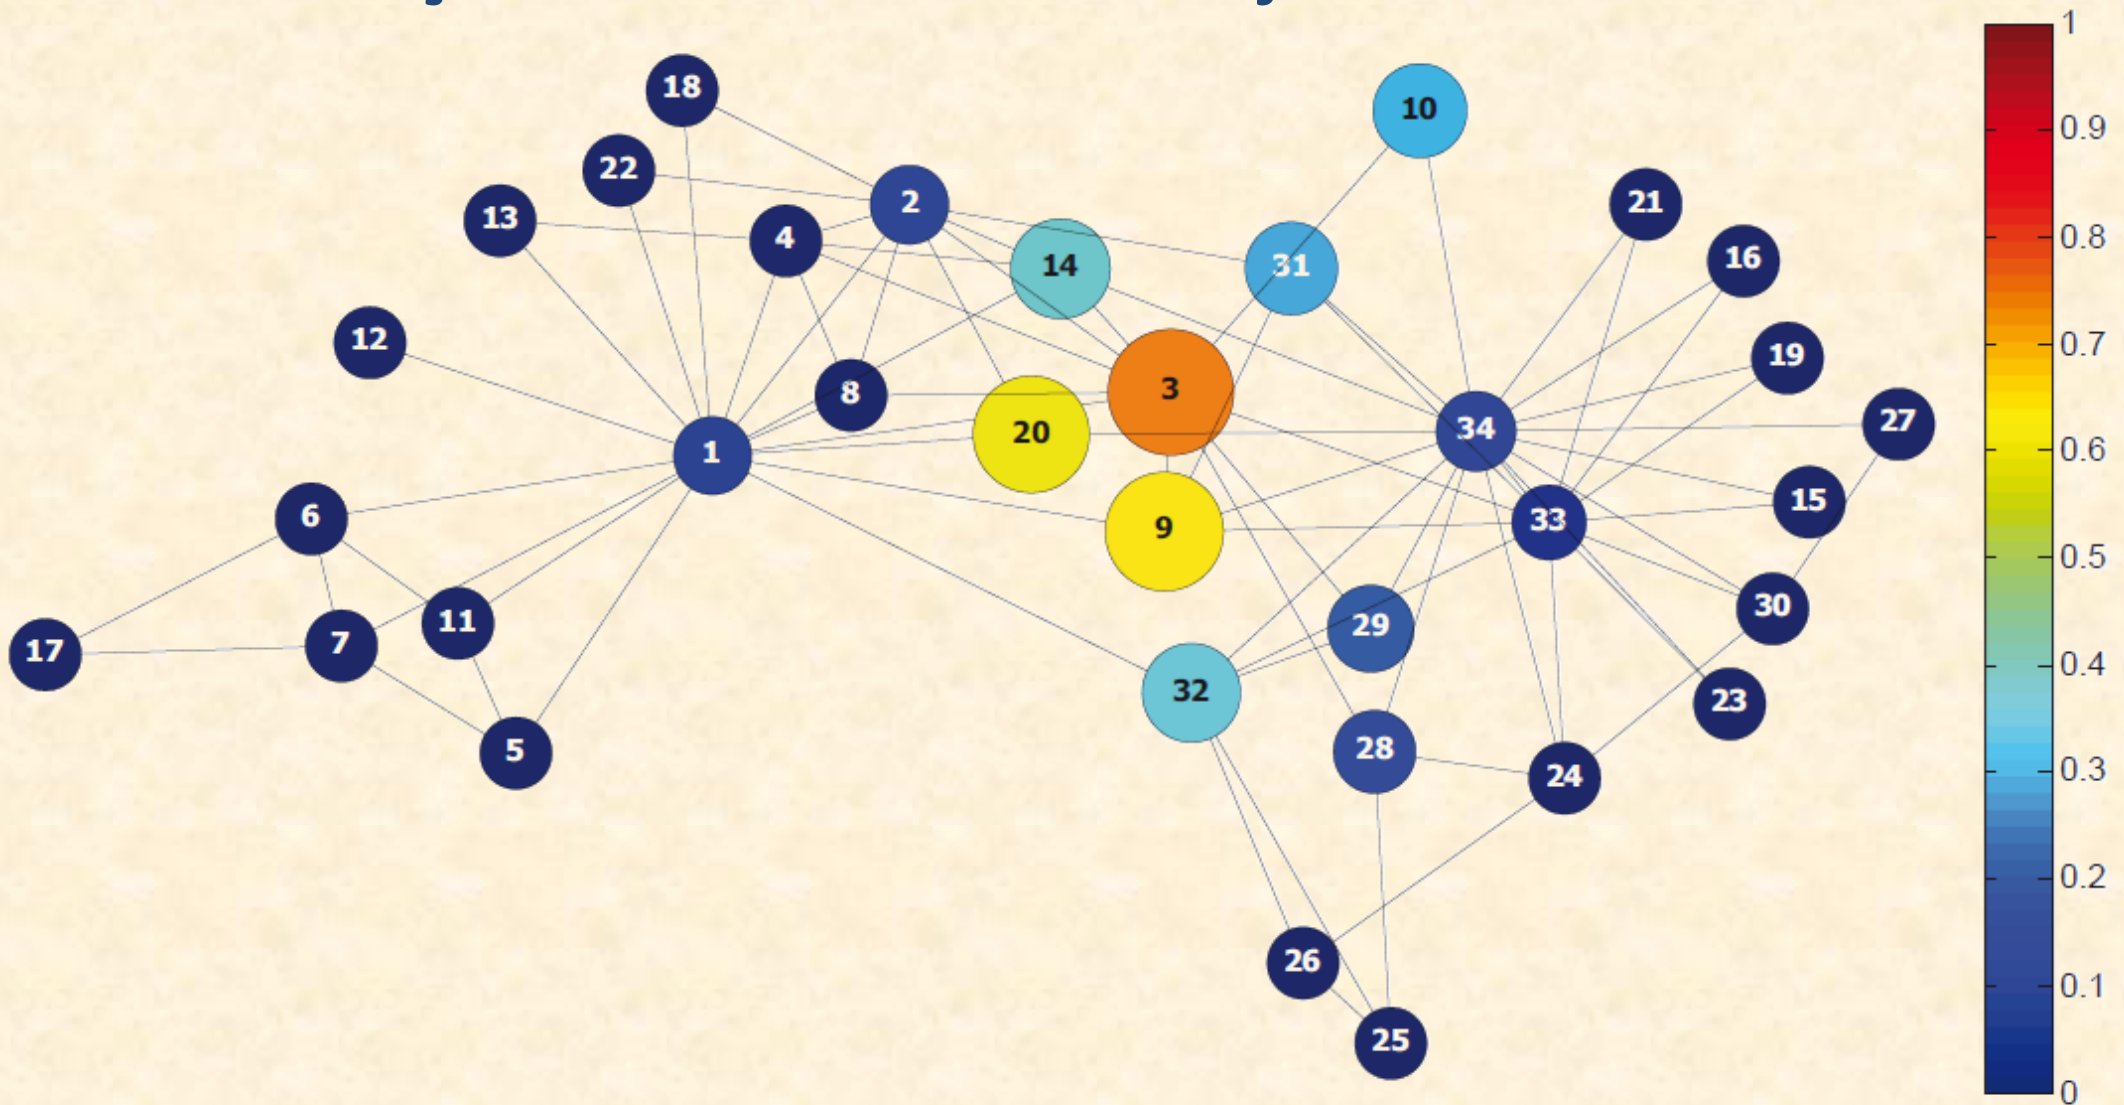
Desempenho de Classificação com presença de *outliers*



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



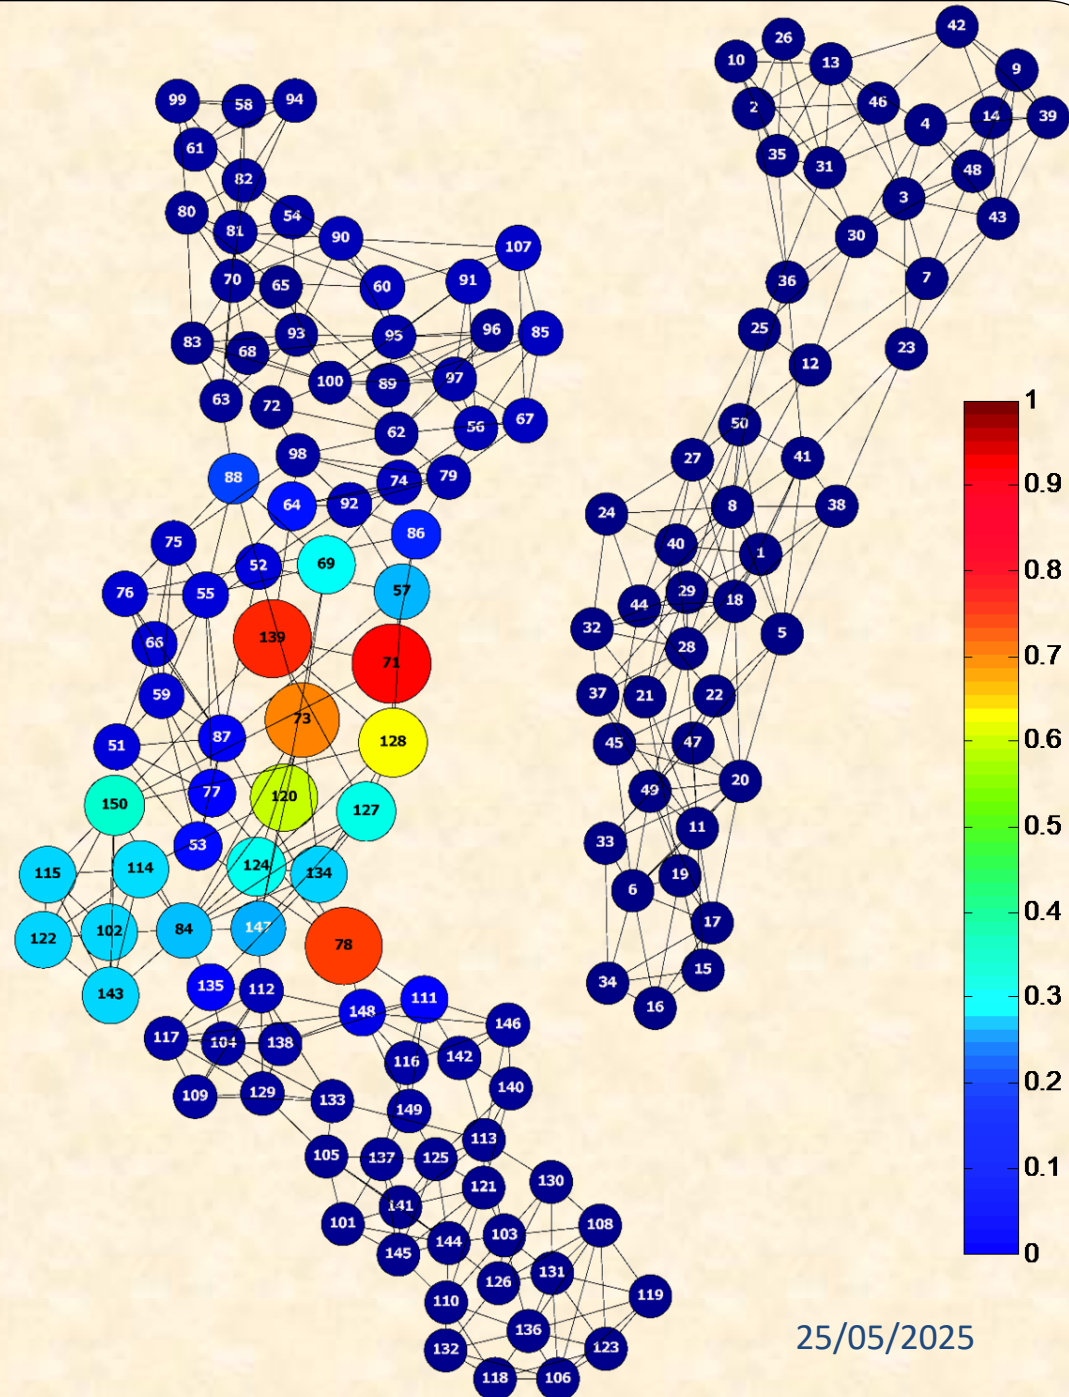
Classificação Nebulosa em Conjuntos de Dados Reais



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

Classificação Nebulosa em Conjuntos de Dados Reais


- O conjunto 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.

Código-Fonte

- MATLAB
 - <https://github.com/fbreve/Particle-Competition-and-Cooperation>



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>


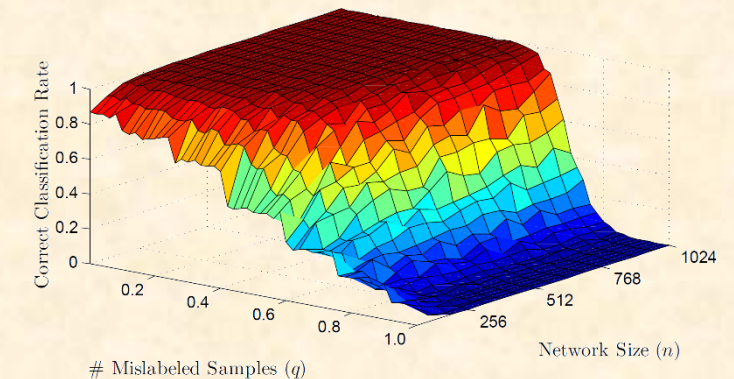
BREVE, Fabricio Aparecido ; ZHAO, Liang . **Particle Competition and Cooperation to Prevent Error Propagation from Mislabeled Data in Semi-Supervised Learning.** In: XII Brazilian Symposium on Neural Network (SBRN 2012), The Brazilian Conference on Intelligent System (BRACIS 2012), 2012, Curitiba, Paraná. *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 todo o conjunto 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 à 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 $Q \subset L \subset N$

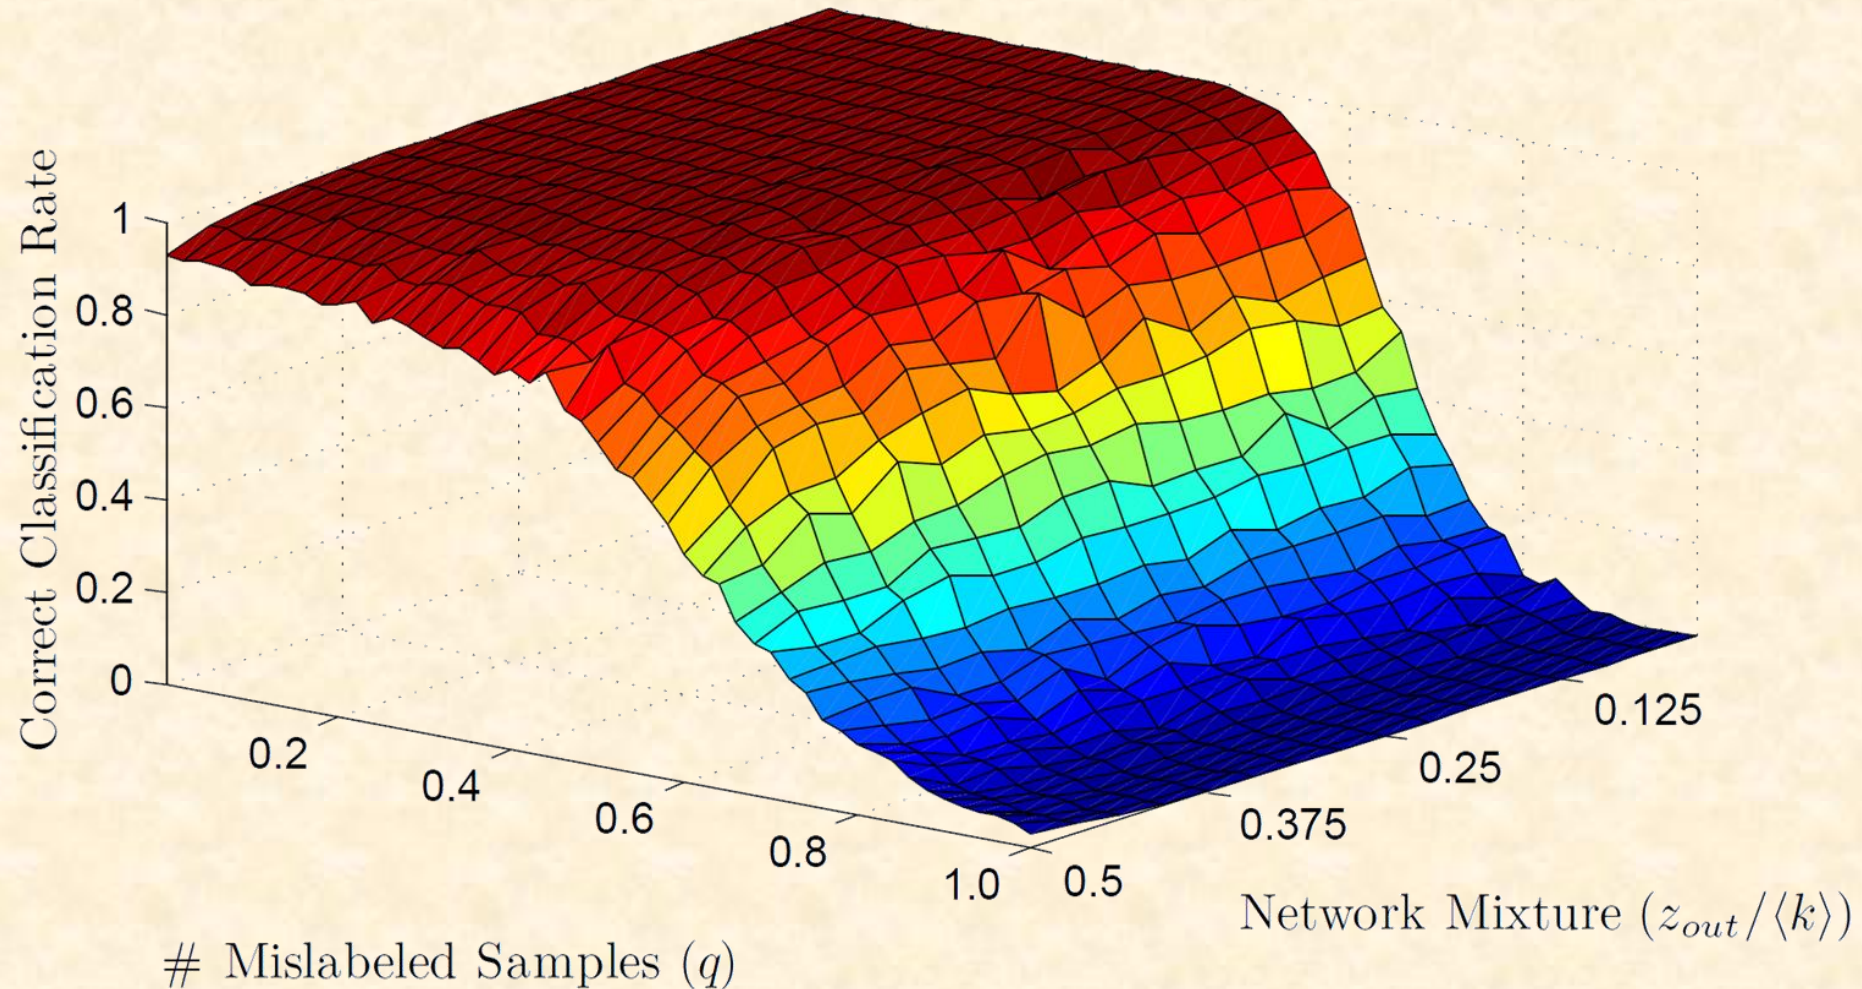


Simulação: Redes com Diferentes Tamanhos




Taxa de Classificação Correta com diferentes tamanhos de redes e diferentes tamanhos do subconjunto de nós com rótulos errados, $\langle k \rangle = n/8$, $z_{out}/\langle k \rangle = 0,25$, $l/n = 0,1$.

Simulação: Redes com Diferentes Misturas



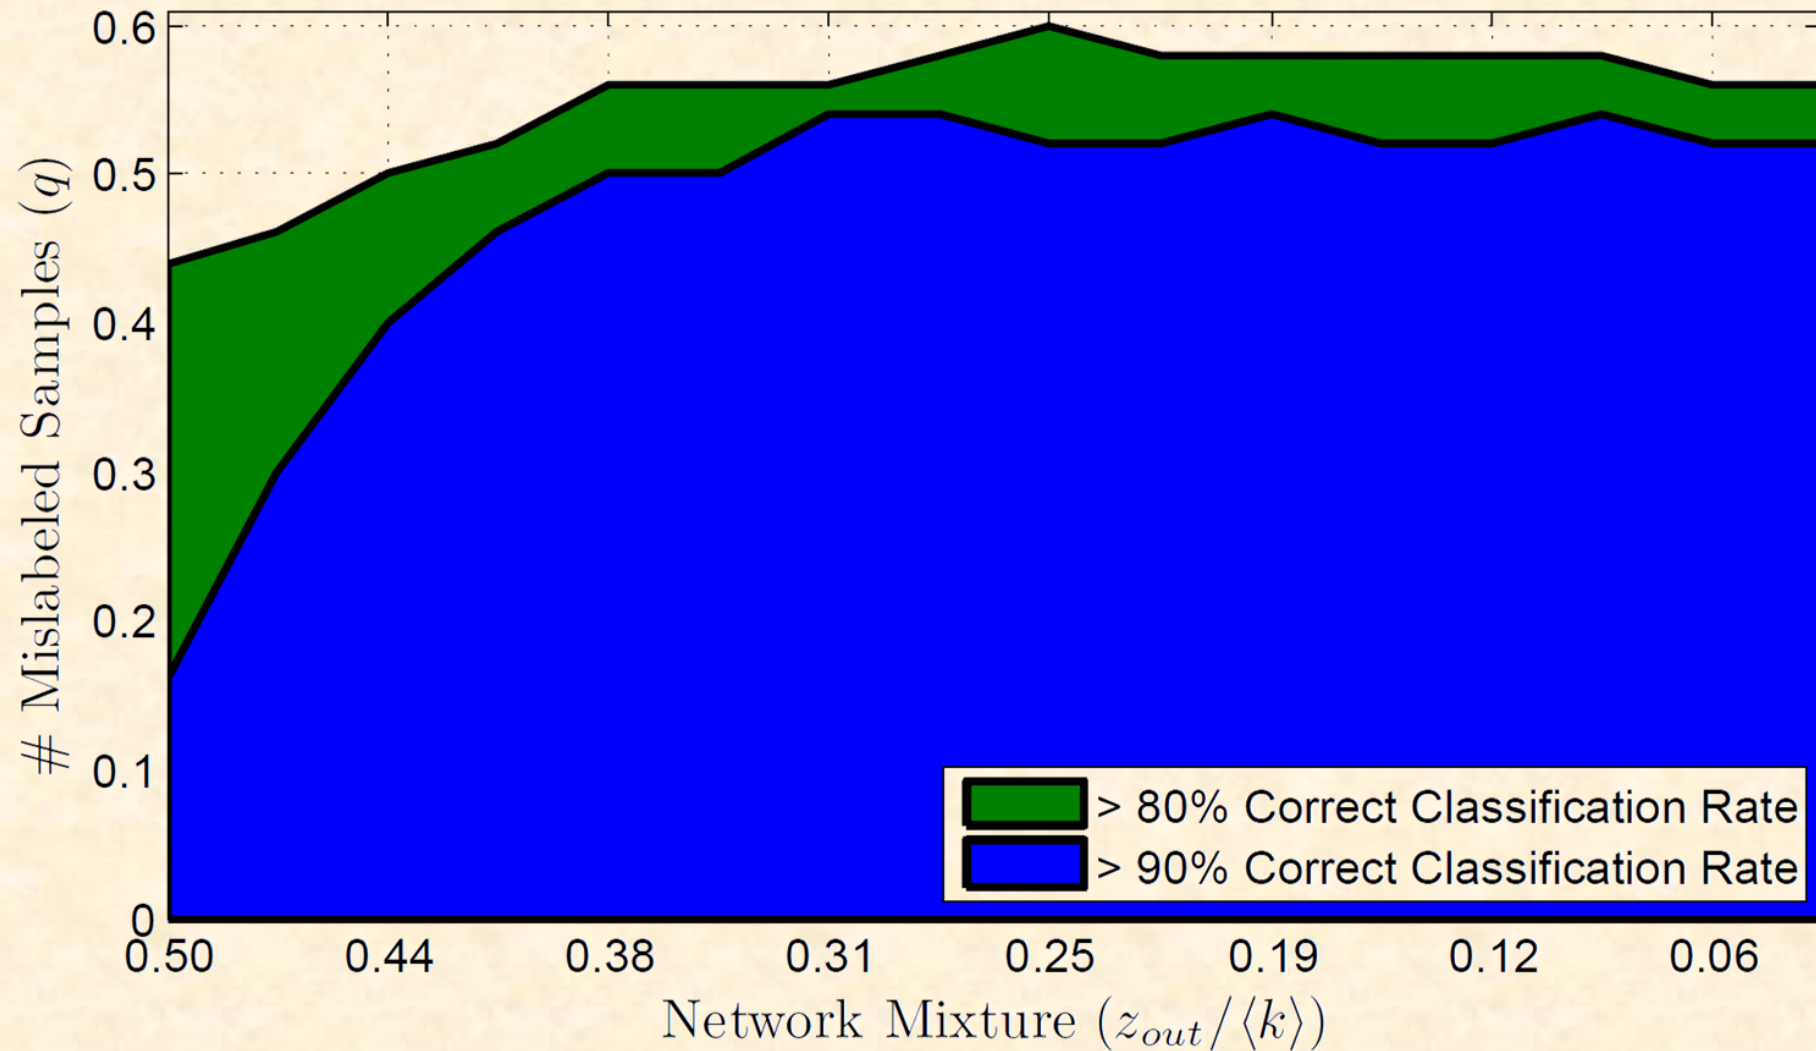
Taxa de Classificação Correta com diferentes misturas de redes e diferentes tamanhos do subconjunto de nós com rótulos errados, $n = 512$, $\langle k \rangle = 64$, $l = 64$.

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

Simulação: Redes com Diferentes Misturas

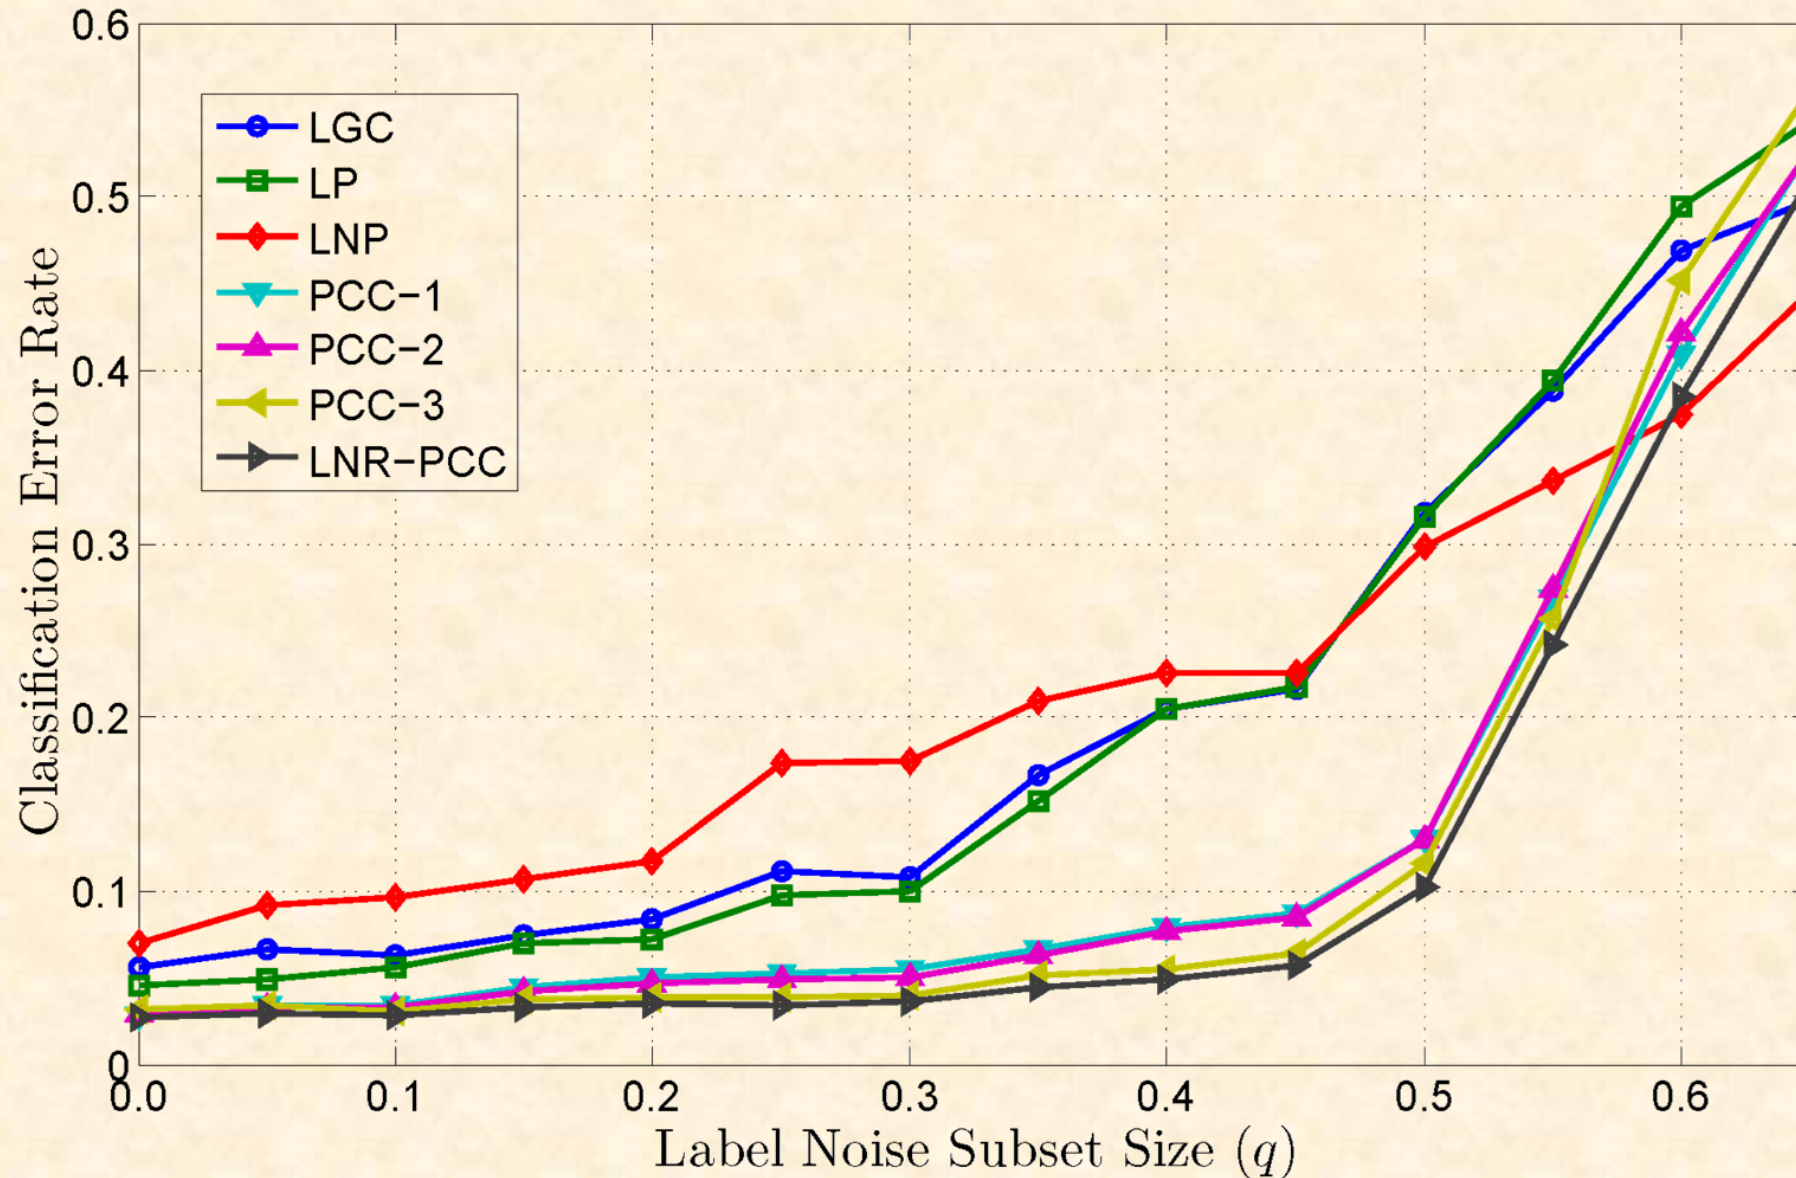


Tamanho máximo do subconjunto de dados rotulados que permite 80% e 90% de taxa de classificação correta com diferentes misturas de redes, $n = 512$, $\langle k \rangle = 64$, $l = 64$.

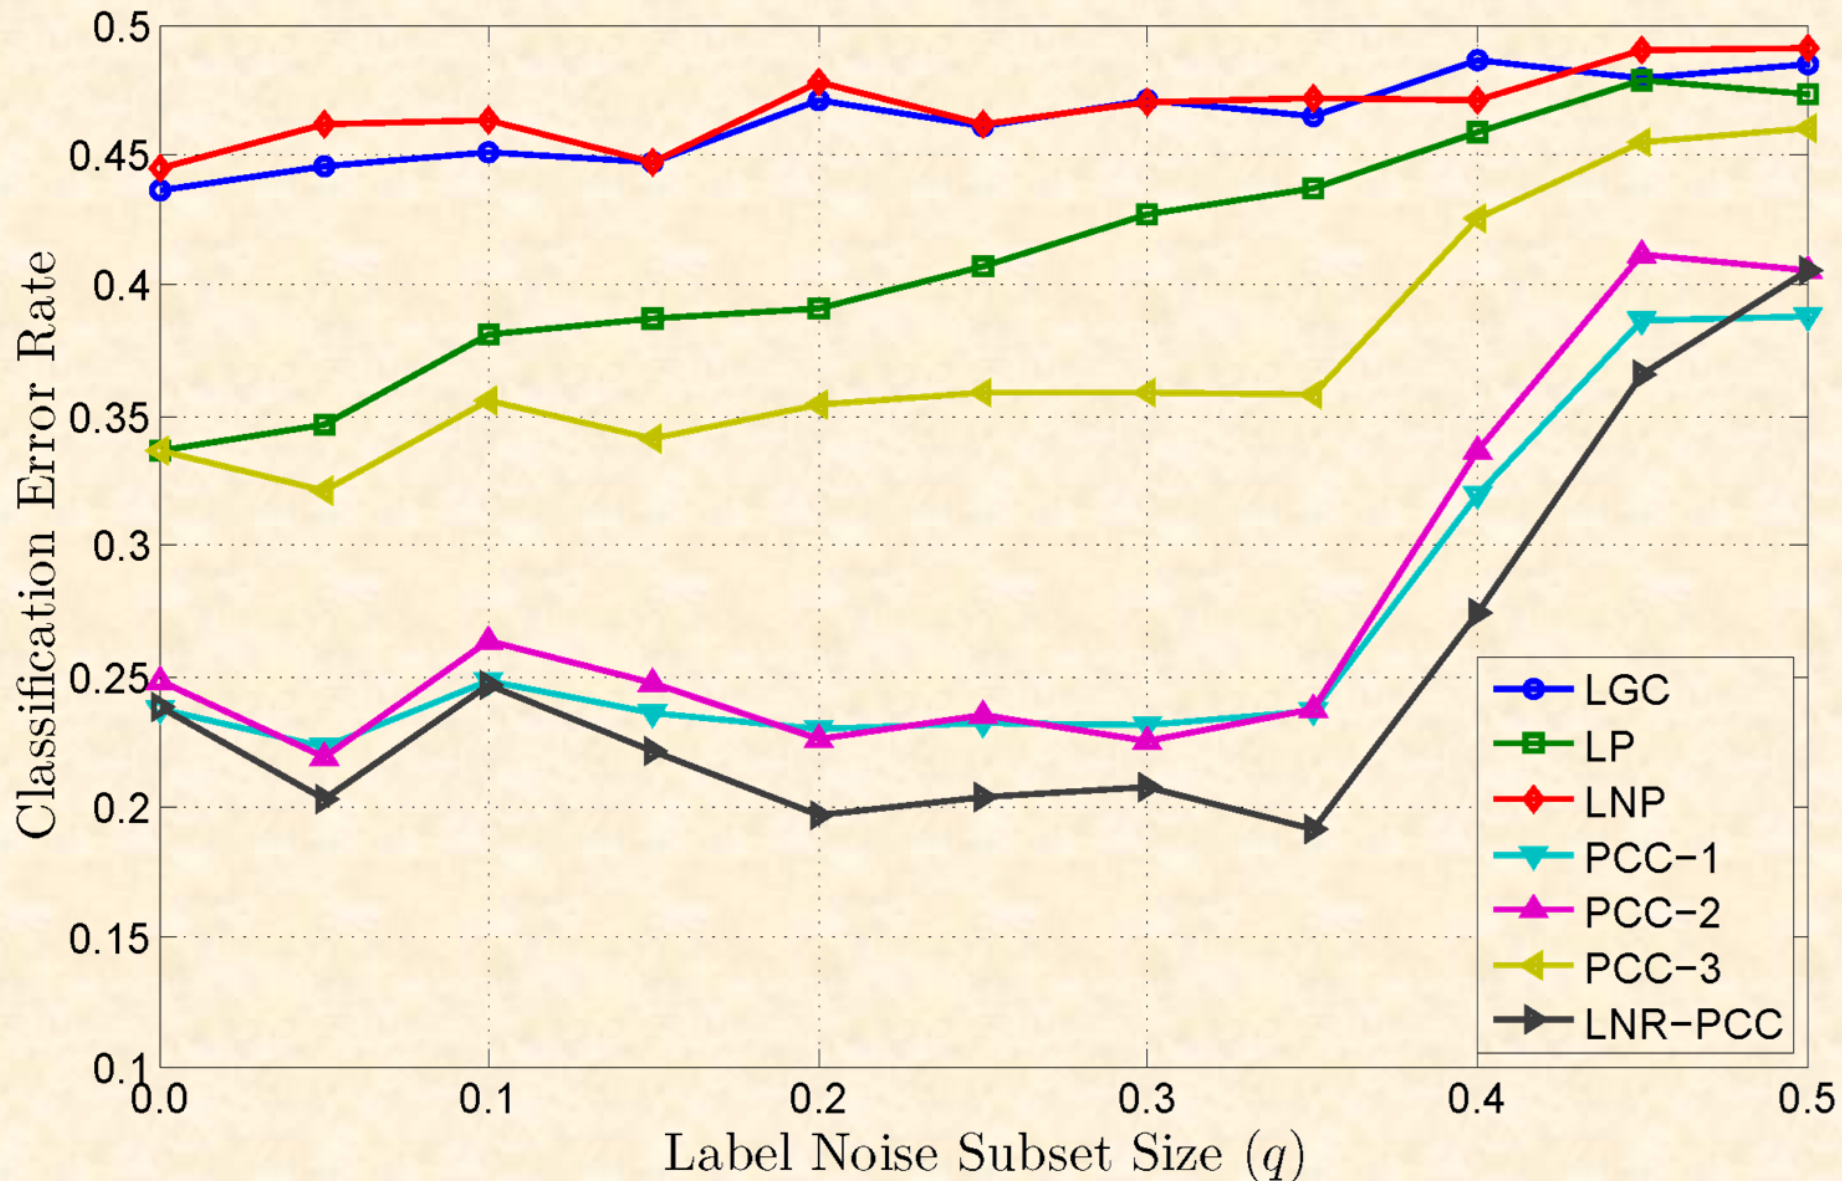
Simulação: Iris



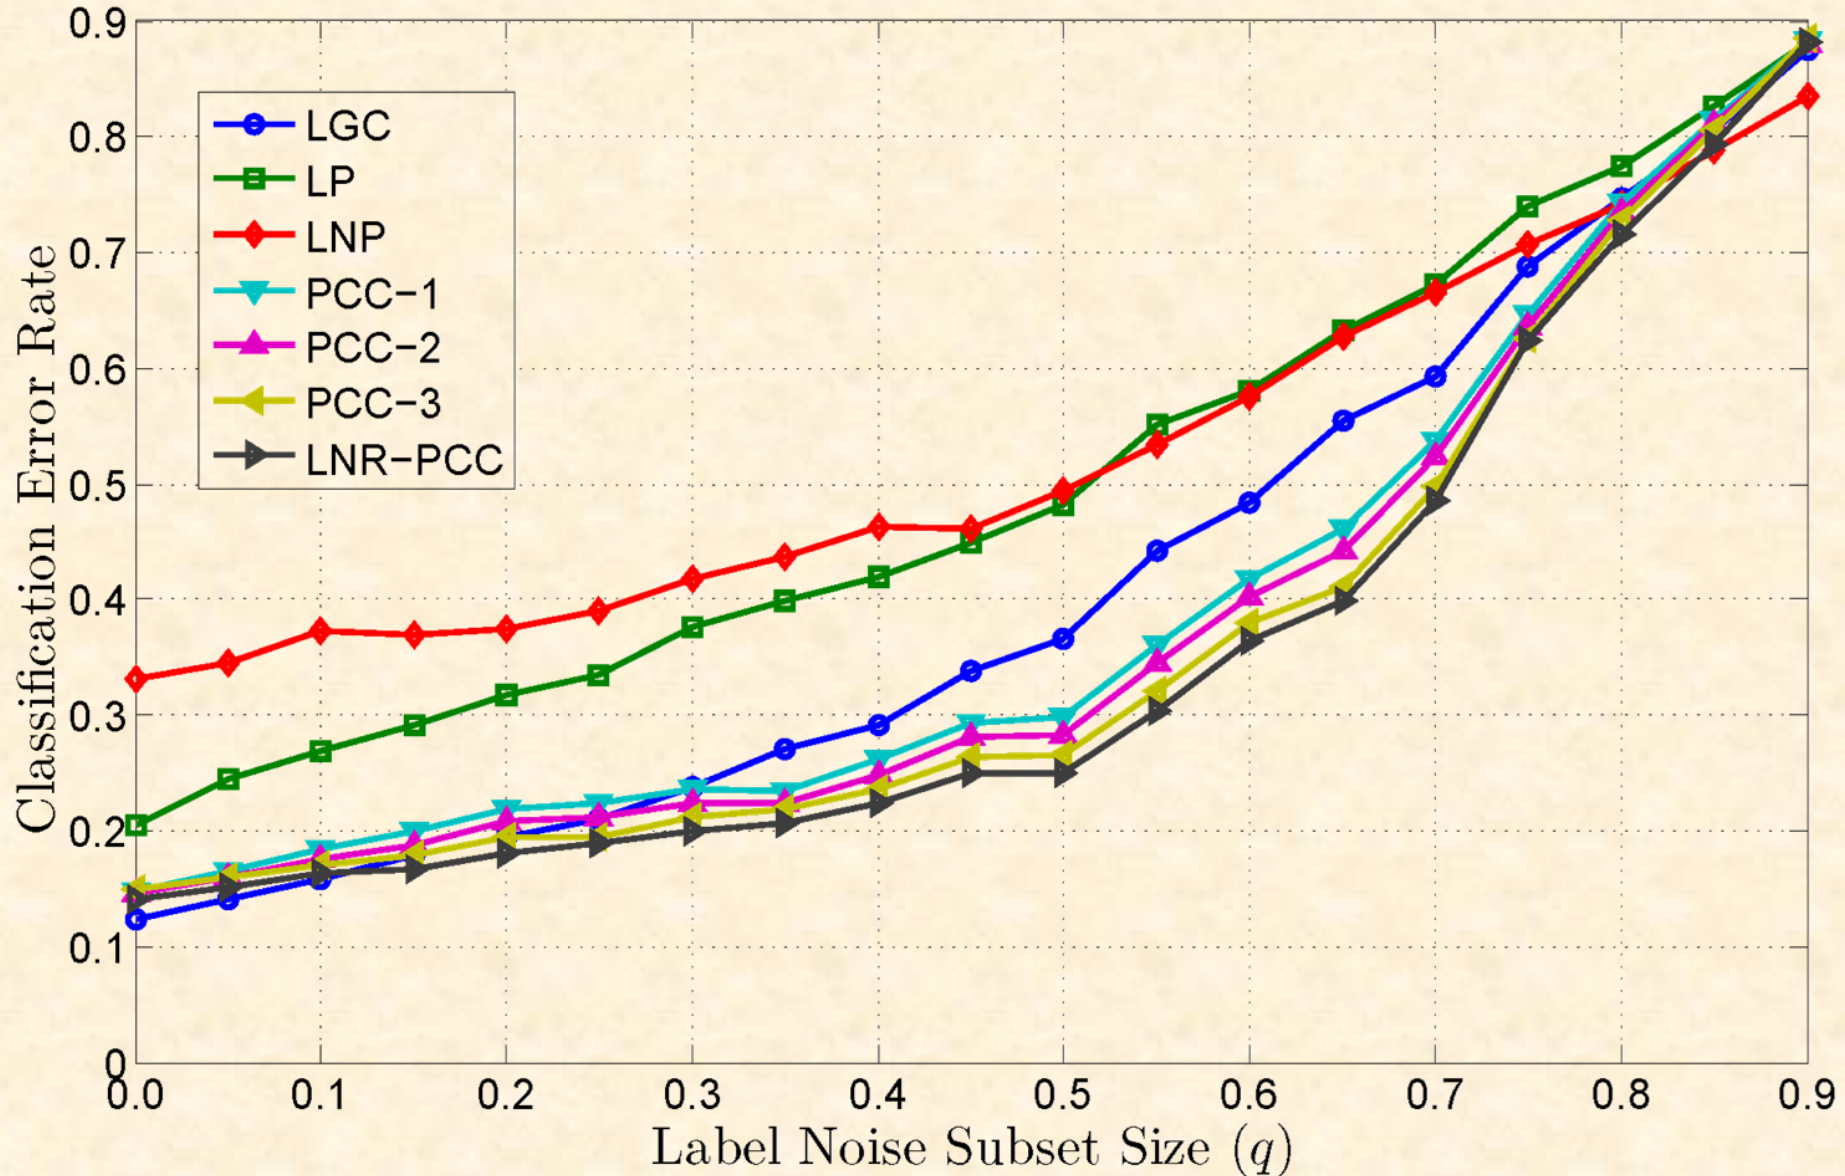
Simulação: Wine



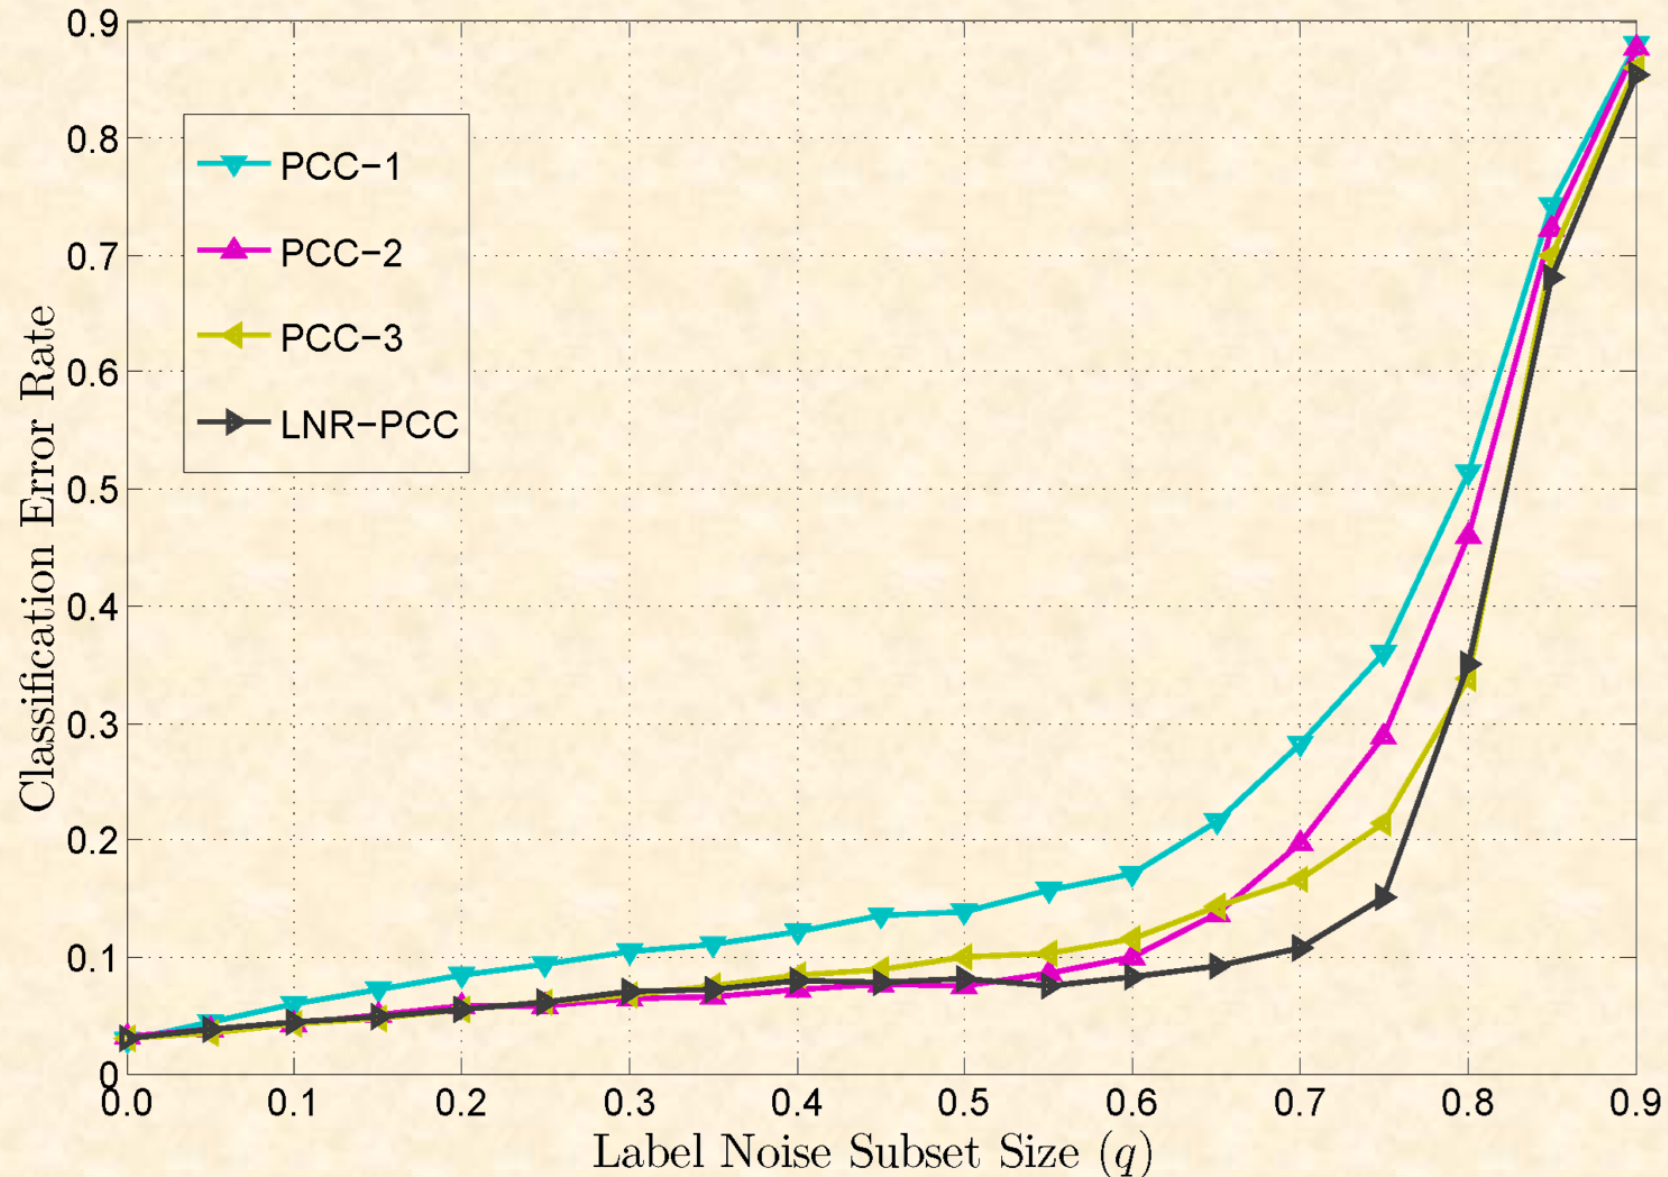
Simulação: g241c



Simulação: Semeion Handwritten Digit



Simulação: Optical Recognition of Handwritten Digits




Código-Fonte

- MATLAB

- <https://github.com/fbreve/LNPCC>

```
>> example  
Parameters k: 10, distance: Normalized Euclidean, others: Default.  
Running the algorithm on the Wine Dat Set with 10% labeled examples, from which 30% have wrong labels (label noise)...  
Classification accuracy: 0.9688 - Execution Time: 0.0840s
```







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>

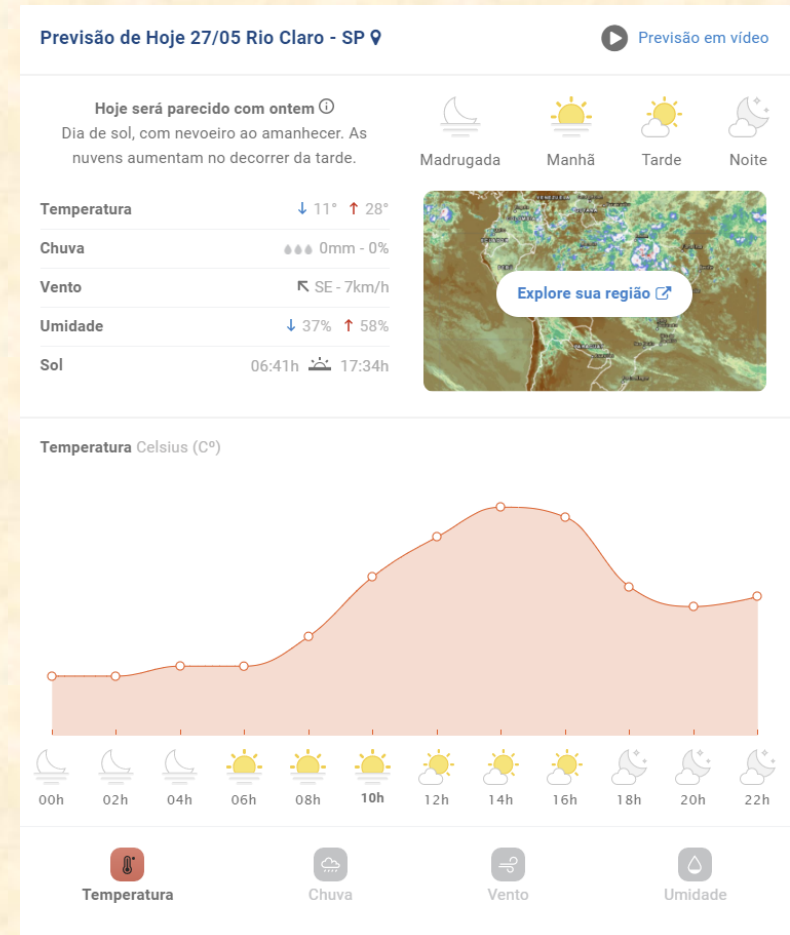
BREVE, Fabricio Aparecido ; ZHAO, Liang . **Semi-Supervised Learning with Concept Drift using Particle Dynamics applied to Network Intrusion Detection Data**. In: 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence, 2013, Ipojuca - Pernambuco. *Proceedings 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>



Classificação Semi-Supervisionada de Fluxos de Dados

- Dados sob análise não são mais apenas estáticos, mas também fluxos de dados em que conceitos e distribuição dos dados podem não ser estáveis através do tempo.
 - Exemplos:
 - Previsão do Tempo
 - Detecção de Fraude
 - Demanda de Energia
 - Muitas outras aplicações do mundo real



Classificação Semi-Supervisionada de Fluxos de Dados


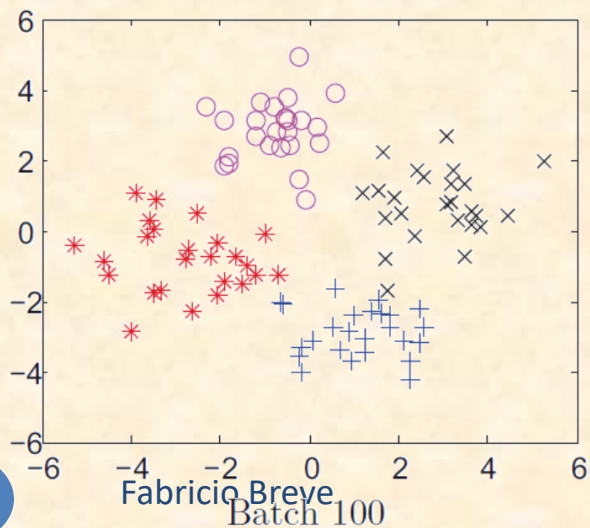


- Os algoritmos de aprendizado precisam lidar com objetivos conflitantes:
 - Reter conhecimento previamente adquirido que ainda é relevante.
 - Substituir qualquer conhecimento obsoleto com informação atual.
- Porém, a maioria dos algoritmos de aprendizado assumem que os dados vem sempre de uma distribuição estática.

- Zliobaite, “**Learning under concept drift: an overview,**” *CoRR*, vol. abs/1010.4784, 2010.
- A. Tsymbal, M. Pechenizkiy, P. Cunningham, and S. Puuronen, “**Dynamic integration of classifiers for handling concept drift,**” *Inf. Fusion*, vol. 9, pp. 56–68, January 2008.
- G. Ditzler and R. Polikar, “**Semi-supervised learning in nonstationary environments,**” in *Neural Networks (IJCNN), The 2011 International Joint Conference on*, 31 2011-aug. 5 2011, pp. 2741 –2748.
- L. I. Kuncheva, “**Classifier ensembles for detecting concept change in streaming data: Overview and perspectives,**” in *Proc. 2nd Workshop SUEMA 2008 (ECAI 2008)*, Patras, Greece, 2008, pp. 5–10.
- A. Bondu and M. Boullé, “**A supervised approach for change detection in data streams,**” in *Neural Networks (IJCNN), The 2011 International Joint Conference on*, 31 2011-aug. 5 2011, pp. 519 – 526.

Modelo de Partículas aplicado à Classificação Semi-Supervisionada de Fluxos de Dados

- Esta extensão apresenta as seguintes características:
 - Os dados do fluxo são transformados em nós da rede à medida que são disponibilizados.
 - A rede tem um tamanho máximo.
 - Quando o tamanho máximo é atingido, os nós mais antigos são rotulados e removidos conforme novos nós são criados.
 - Há um limite na quantidade de partículas.
 - Quando o limite é atingido, as partículas mais antigas são eliminadas conforme novas partículas são criadas.
 - Tabelas de distâncias não são utilizadas.


Simulação: Mudança Lenta de Conceito



- $n = 50.000$ itens de dados.
- 500 lotes.
- 100 itens de dados em cada lote.
- Itens de dados gerados em torno de 4 núcleos Gaussianos se movendo no sentido horário.
- 100.000 movimentos de partículas entre a chegada de cada lote.
- 10% dos itens de dados rotulados, 90% não rotulados.
- $k = 5$.

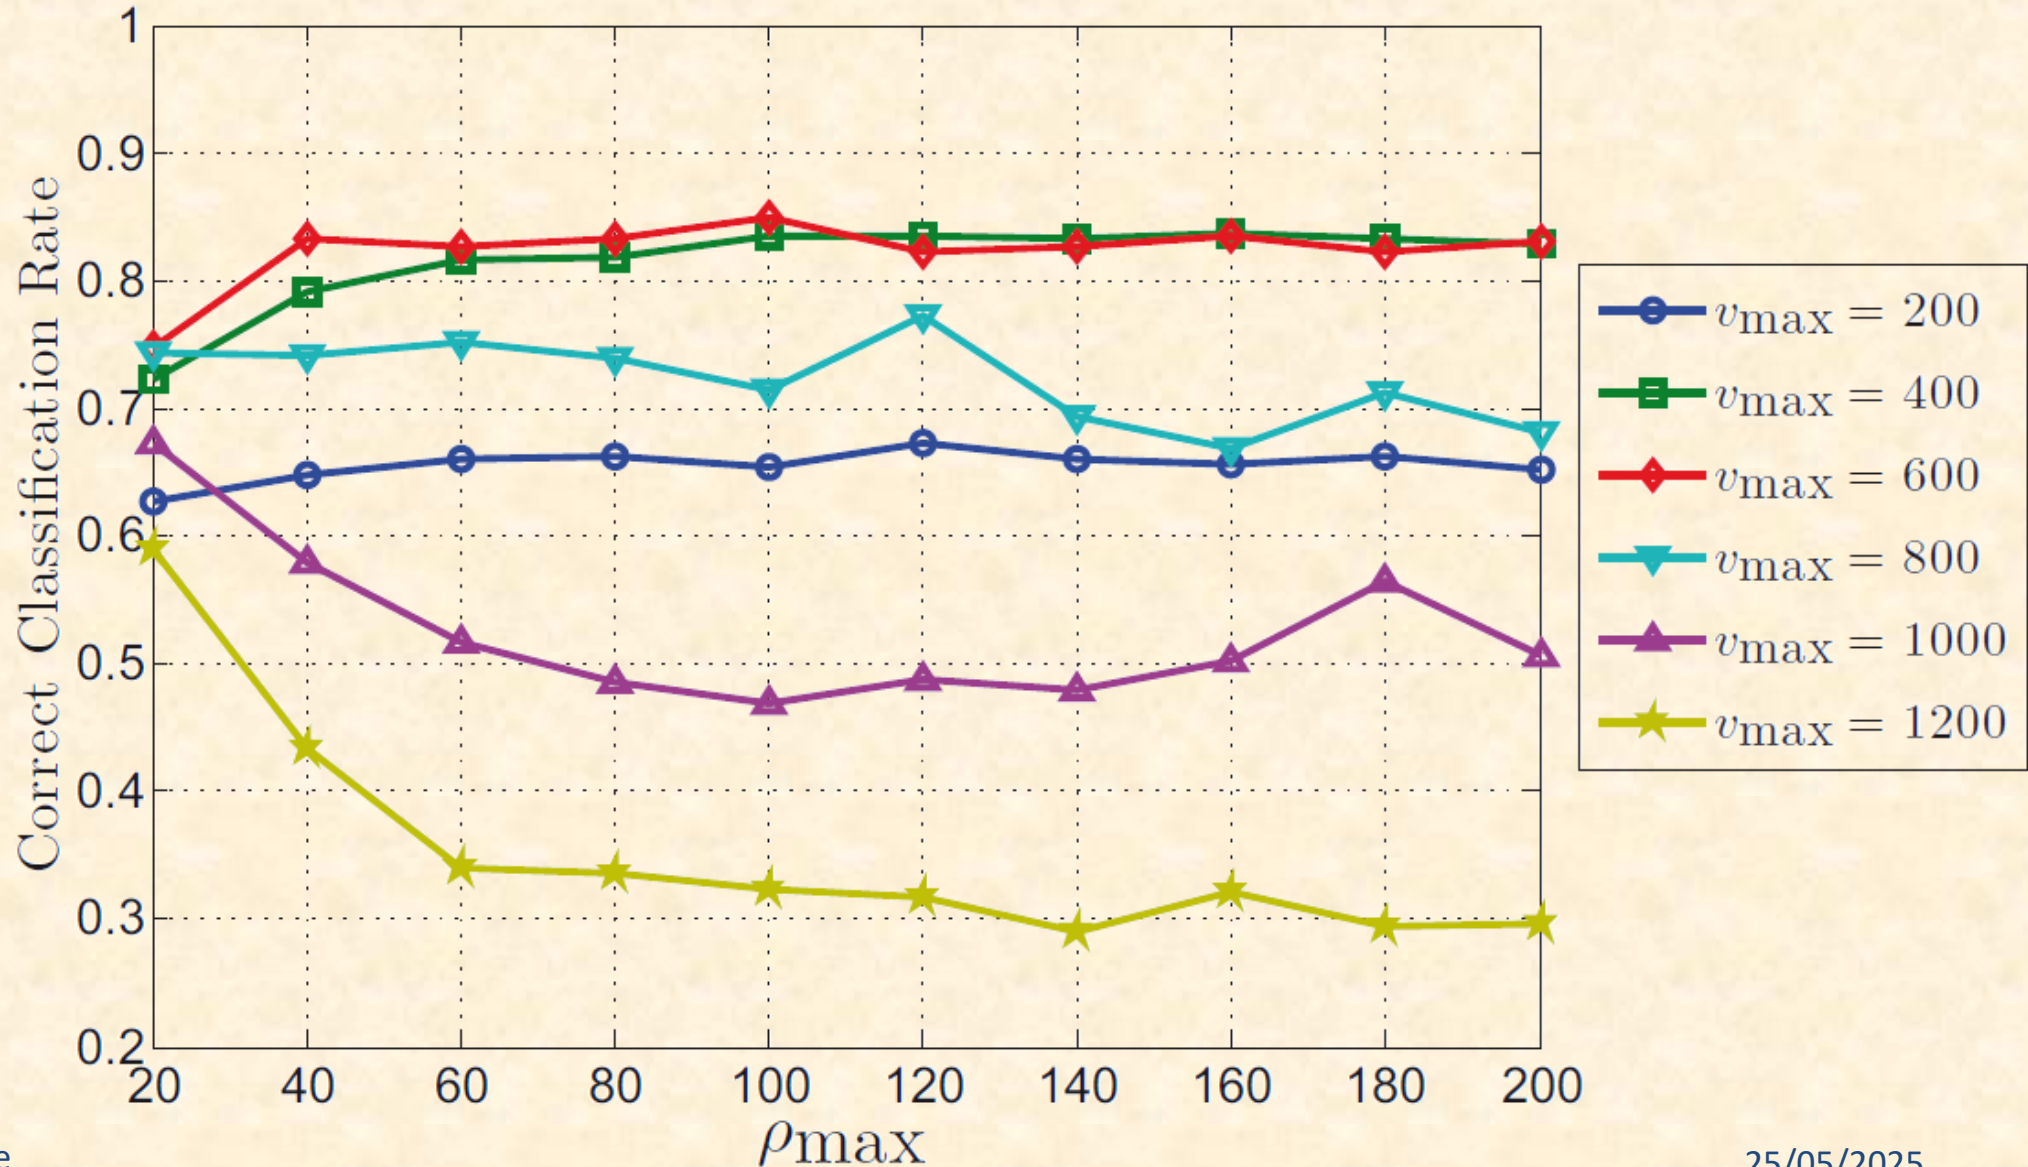
Simulação: Mudança Lenta de Conceito

Simulação 1:
Mudança Lenta de
Conceito. Taxa de
Classificação
Correta variando o
tamanho máximo
da rede (v_{max}) e a
quantidade
máxima de
partículas (ρ_{max}).
 $n = 50.000$.




Simulação: Mudança Rápida de Conceito

Simulação 2:
Mudança Rápida
de Conceito.
Taxa de
Classificação
Correta variando
o tamanho
máximo da rede
(v_{max}) e a
quantidade
máxima de
partículas (ρ_{max}).
 $n = 10.000$.



Simulação: Conjunto de Dados KDD Cup 1999

Simulação 3:
Conjunto de Dados
KDD Cup 1999 com
10% de dados
rotulados. Taxa de
Classificação
Correta variando o
tamanho máximo
da rede (v_{max}) e a
quantidade
máxima de
partículas (ρ_{max}).
 $n = 494.021$




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.



Aprendizado Ativo

- Forma de aprendizado de máquina em que o algoritmo de aprendizado pode interagir com um especialista humano (ou outra fonte de informação) para obter rótulos para itens de dados selecionados.
- Ideia chave é que o algoritmo de aprendizado pode obter maior taxa de classificação correta com menos dados de treinamento se puder **escolher a partir de quais dados aprenderá.**



- B. Settles, “**Active learning,**” *Synthesis Lectures on Artificial Intelligence and Machine Learning*, vol. 6, no. 1, pp. 1–114, 2012.
- F. Olsson, “**A literature survey of active machine learning in the context of natural language processing,**” Swedish Institute of Computer Science, Box 1263, SE-164 29 Kista, Sweden, Tech. Rep. T2009:06, April 2009.

Aprendizado Ativo e Semi-Supervisionado

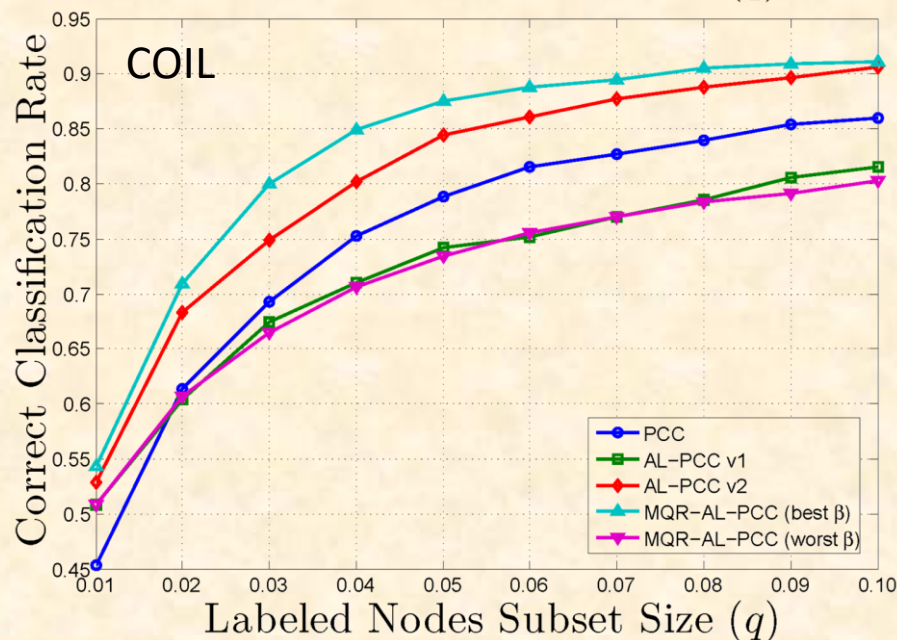
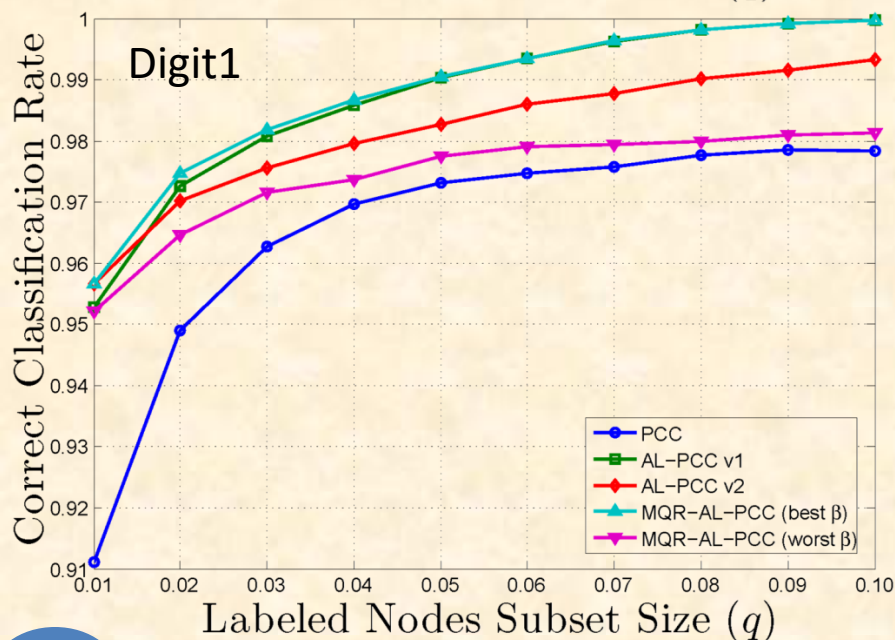
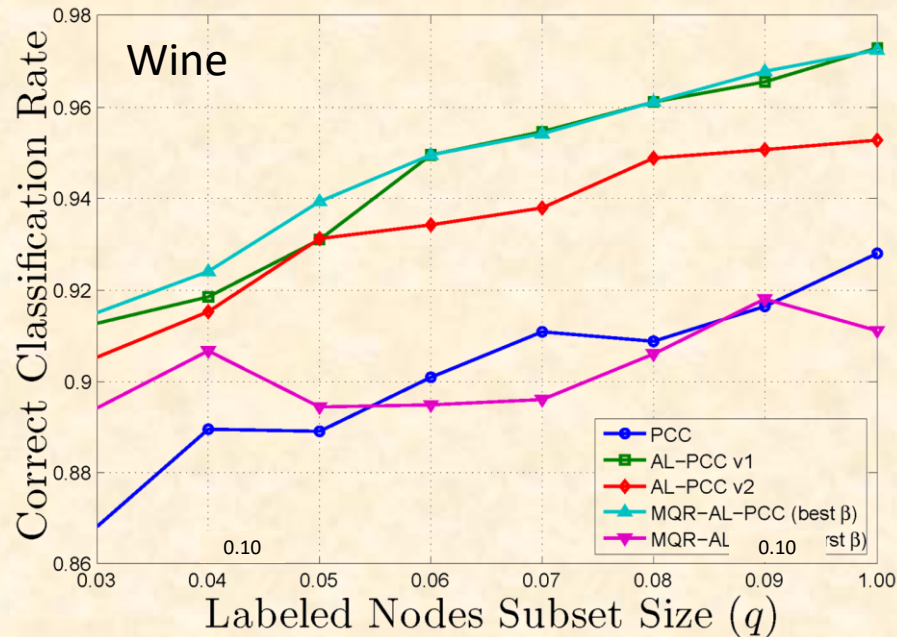

- Aprendizado Ativo e Semi-Supervisionado tem algumas características em comum:
 - Ambos tentam aproveitar ao máximo os dados não rotulados.
 - Ambos são indicados em casos onde há muitos dados não rotulados e o processo de rotular é difícil e/ou caro.
- Mas há diferenças:
 - Aprendizado Semi-Supervisionado explora o que o algoritmo acha que sabe sobre os dados não rotulados.
 - Exemplo: Conjunto de classificadores pode ser re-treinado iterativamente incorporando como dados rotulados aqueles em que a maioria dos algoritmos concordam com o rótulo fornecido (maior confiança).
 - Aprendizado Ativo tenta explorar os aspectos desconhecidos.
 - Exemplo: Itens de dados que os classificadores mais discordaram podem ser selecionados para a consulta com o especialista humano (amostragem por incerteza).

Modelo de Partículas aplicado ao Aprendizado Ativo e Semi-Supervisionado

- Apenas um exemplo rotulado por classe é necessário para que o algoritmo inicie.
- Novas partículas são inseridas à medida que rótulos são obtidos para exemplos previamente não rotulados.
- Ao contrário de outros algoritmos, não precisa ter o processo de treinamento reiniciado conforme novos rótulos chegam.
 - O algoritmo se adapta para incorporar novos nós rotulados e novas partículas.
- Apenas nós afetados pela mudança precisam ser reclassificados.
 - Equilíbrio é rapidamente reestabelecido.

Modelo de Partículas aplicado ao Aprendizado Ativo e Semi-Supervisionado

- Como o algoritmo de partículas escolhe os nós que serão rotulados pelo especialista?
 - Nós com maior incerteza.
 - Calculado a partir dos níveis de domínio.
 - Semelhante ao nível de sobreposição na extensão para detecção de comunidades sobrepostas.
 - Nós mais distantes de qualquer nó rotulado.
 - Calculado a partir das tabelas de distâncias das partículas.



Taxa de classificação correta quando o método é aplicado em diferentes conjuntos de dados com diferentes parâmetros β (que define o balanço entre as duas regras de seleção de nós) e diferentes tamanhos de subconjunto de dados rotulados. Os conjuntos de dados são: Iris, Wine, Digit1, e COIL.

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.

RIBEIRO PASSERINI, Jefferson Antonio; BREVE, Fabricio Aparecido. **Complex Network Construction for Interactive Image Segmentation using Particle Competition and Cooperation: A New Approach** In: The 20th International Conference on Computational Science and its Applications (ICCSA2020), 2020, Cagliari, Itália. *Lecture Notes in Computer Science (LNCS)*. Cham, Suíça: Springer International Publishing AG, 2020.



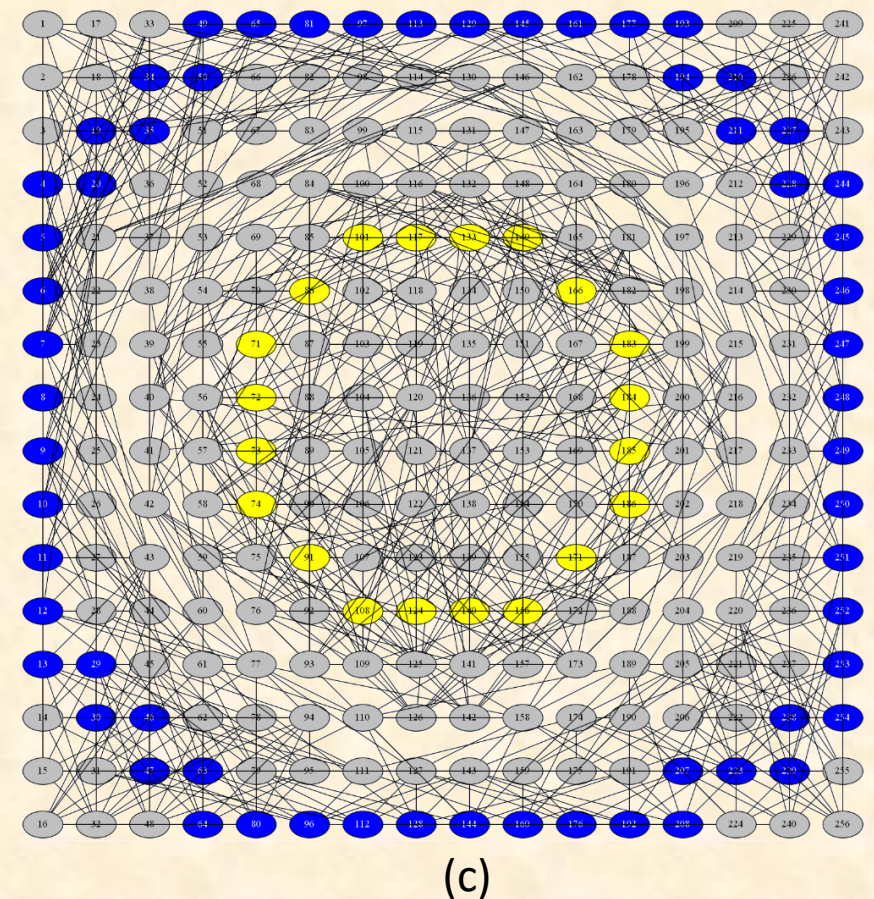

Segmentação de Imagens

- 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.




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



Fabrizio Breve

(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
























Simulações Computacionais

- Mesmos 20 atributos das simulações anteriores.
- k e peso dos atributos otimizados com Algoritmo Genético.
- Após competição de partículas, um segundo passo iterativo de propagação é usado para definir pixels cujo rótulo foi atribuído com alto grau de incerteza.
 - Propagação ocorre considerando apenas vizinhança entre pixels na imagem, ponderada pela distância Euclidiana entre seus atributos.

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>



(a)



(b)



(c)


(a) Imagem Original; (b) Regiões semente, com pixels em branco e em cinza escuro representando dados rotulados, e cinza claro representando região a ser rotulada pelo método; e (c) Resultado de segmentação com o modelo de partículas.

por Fabricio Breve




Microsoft GrabCut dataset

Imagem Original



Regiões Sementes



Ground Truth






Resultado da Segmentação

Erro: 6,19%

25/05/2025



Microsoft GrabCut dataset



Erro: 1,53%





Microsoft GrabCut dataset



Erro: 1,09%

25/05/2025




Erro: 1,24%

25/05/2025


Segmentação Interativa de Imagens usando Propagação de Rótulos em Redes Complexas

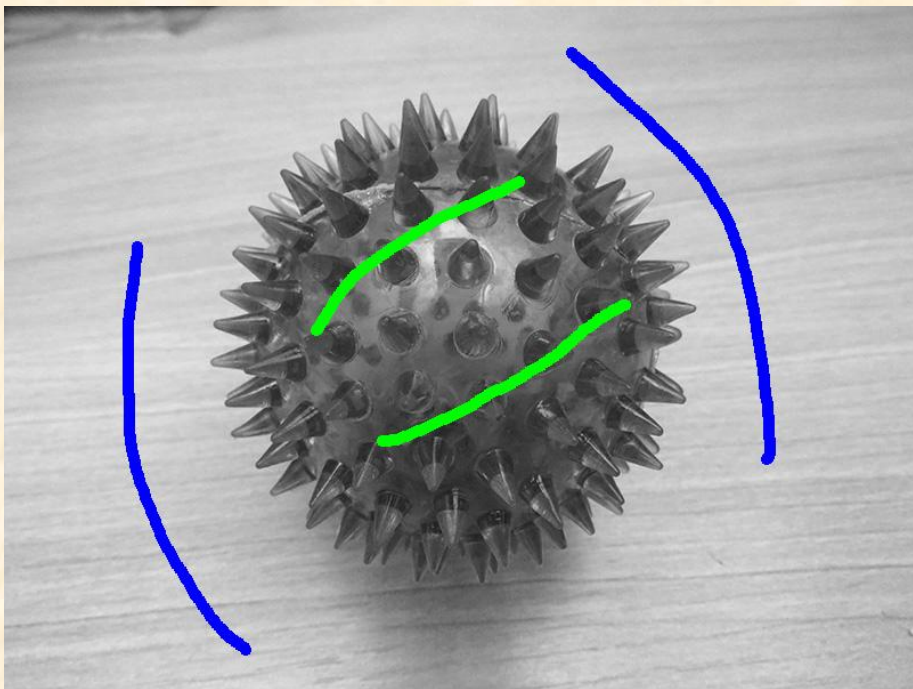
BREVE, Fabricio Aparecido. **Interactive Image Segmentation using Label Propagation through Complex Networks.** *Expert System With Applications*, v. 123, p.18 – 33, 2019.





Segmentação Interativa de Imagens usando Propagação de Rótulos em Redes Complexas



- Primeiro passo com rede complexa montada usando grafo 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).
- Apenas 9 atributos:
 - Posição do pixel nos eixos horizontal e vertical.
 - Componentes RGB (vermelho, verde, azul).
 - Componente V (intensidade) de HSV.
 - Componentes ExR, ExG, ExB.














Comparação das taxas médias de erro obtidas no conjunto de dados GrabCut pelo método proposto e outros métodos iterativos de segmentação de imagens.

Método	Taxa de Erro
sDPMNL (boundary) (Ding et al., 2012)	11,43%
GMMVL (location + color + boundary) (Yi et al., 2004)	10,45%
SVM (location + color + boundary) (Chang and Lin, 2011)	9,21%
GM-MRF (Blake et al., 2004)	7,90%
sDPMNL (color) (Ding et al., 2012)	7,65%
Superpixels Hypergraph (Ding and Yilmaz, 2008)	7,30%
Lazy Snapping (Li et al., 2004)	6,65%
Graph Cuts (Boykov and Jolly, 2001)	6,60%
Cost volume filtering (Hosni et al., 2013)	6,20%
Directed Image Neighborhood Hypergraph (Ducournau and Bretto, 2014)	6,15%
RobustP ⁿ (Kohli et al., 2009)	6,08%
Grabcut (Rother et al., 2004)	5,46%
Regularized Laplacian (Duchenne et al., 2008)	5,40%
Grady's random walker (Grady, 2006)	5,40%
Probabilistic Hypergraph (Ding and Yilmaz, 2010)	5,33%
DPMVL (color + boundary) (Ding et al., 2012)	5,19%
Laplacian Coordinates (Casaca et al., 2014)	5,04%
sDPMVL (color + boundary) (Ding et al., 2012)	4,78%
Sub-Markov Random Walk (Dong et al., 2016)	4,61%
Normalized Lazy Random Walker (Bampis et al., 2017)	4,37%
Normalized Random Walker (Bampis et al., 2017)	4,35%
Nonparametric Higher-Order (Kim et al., 2010)	4,25%
Método Proposto (parâmetros padrões)	4,15%
Constrained Random Walks (Yang et al., 2010)	4,08%
Lazy Randow Walks (Shen et al., 2014)	3,89%
Robust Multilayer Graph Constraints (Wang et al., 2016a)	3,79%
Texture Aware Model (Zhou et al., 2013)	3,64%
Pairwise Likelihood Learning (Wang et al., 2017)	3,49%
Multi-layer Graph Constraints (Wang et al., 2016b)	3,44%
Método Proposto (k otimizado)	3,21%
Random Walks with Restart (Kim et al., 2008)	3,11%
Normalized Sub-Markov Random Walk (Bampis et al., 2017)	3,10%
Difusive Likelihood (Wang et al., 2018b)	3,08%

Comparação do tempo médio de execução obtido em todas as 20 imagens de tamanho 321 × 481 no conjunto de dados Microsoft GrabCut pelo método proposto e outros métodos iterativos de segmentação de imagens, usando os *trimaps* originais.


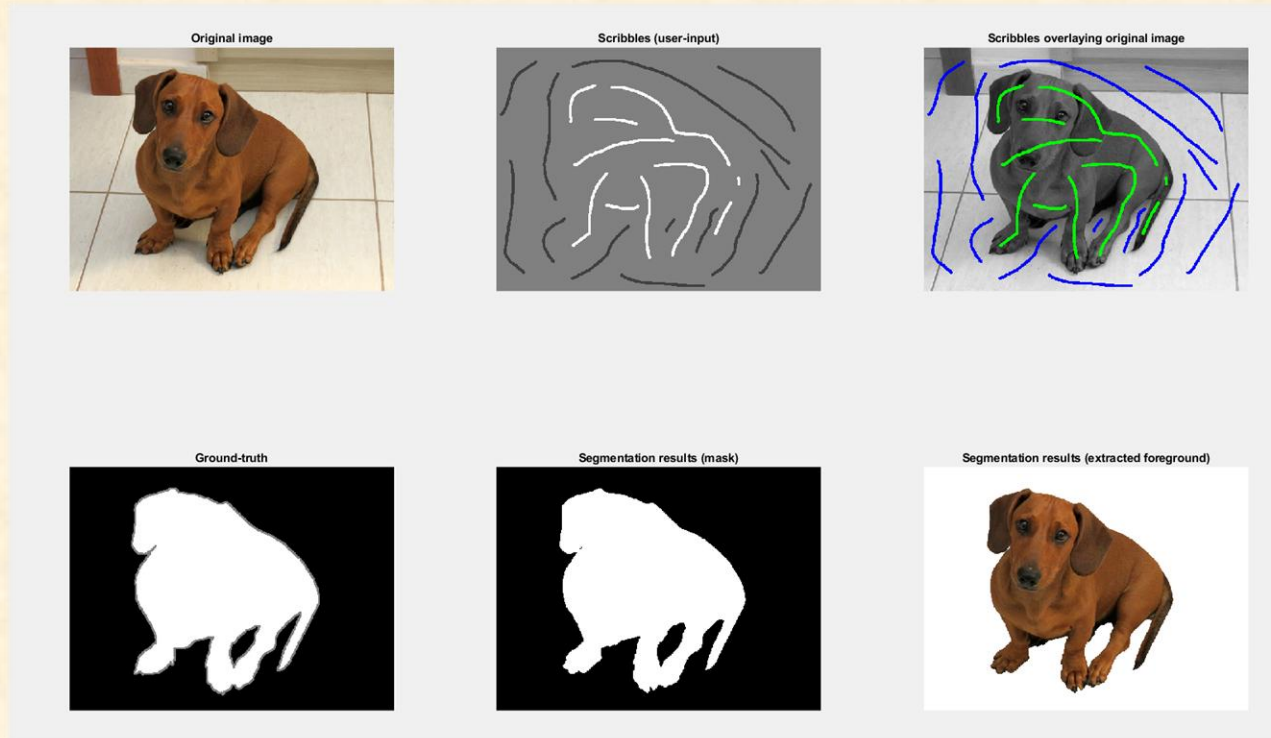
Método	Tempo (s)
Nonparametric Higher-Order (Kim et al., 2010)	11,0
Multi-layer Graph Constraints (Wang et al., 2016b)	5,4
Sub-Markov Random Walk (Dong et al., 2016)	5,1
Diffusive Likelihood (Wang et al., 2018b)	3,4
Laplacian Coordinates (Casaca et al., 2014)	3,2
Grady's random walker (Grady, 2006)	0,8
GrabCut (Rother et al., 2004)	0,7
Método Proposto (parâmetros padrões)	0,3

Comparação das taxas de erro médias obtidas no conjunto de dados GrabCut pelo método proposto e outros métodos iterativos de segmentação de imagens, utilizando os conjuntos de "rabiscos" de Andrade e Carrera (2015).

Método	Erro	
	<i>S</i> ₁	<i>S</i> ₂
Random Walks with Restart (Kim et al., 2008)	6,65%	6,44%
Lazy Randow Walks (Shen et al., 2014)	6,42%	6,12%
Normalized Sub-Markov Random Walk (Bampis et al., 2017)	6,07%	5,81%
Sub-Markov Random Walk (Dong et al., 2016)	6,07%	5,81%
Grady's random walker (Grady, 2006)	5,58%	2,91%
Laplacian Coordinates (Casaca et al., 2014)	5,37%	3,75%
Normalized Lazy Random Walker (Bampis et al., 2017)	4,80%	2,49%
Normalized Random Walker (Bampis et al., 2017)	4,77%	2,48%
Método Proposto (parâmetros padrões)	3,68%	1,60%
Método Proposto (k otimizado)	2,28%	1,21%

Código-Fonte

- MATLAB
 - <https://github.com/fbreve/LPCN>



Novas Aplicações

Auxílio no Diagnóstico da Doença de Alzheimer


Auxílio para Deficientes Visuais (Detecção de Obstáculos)

Novas Aplicações

- O modelo de competição e cooperação entre partículas tem se mostrado eficaz na classificação de imagens, usando **redes neurais convolucionais** pré-treinadas como extratoras de atributos.
 - Auxílio no Diagnóstico da Doença de Alzheimer.
 - OLIVEIRA CARNELOZ, Caio. **Auxílio no diagnóstico da doença de Alzheimer a partir de imagens de ressonância magnética utilizando competição e cooperação entre partículas.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2019. (Dissertação de Mestrado).
 - Auxílio para Deficientes Visuais (Detecção de Obstáculos)
 - BREVE, Fabricio Aparecido; FISCHER, Carlos Norberto. **Visually Impaired Aid using Convolutional Neural Networks, Transfer Learning, and Particle Competition and Cooperation** In: 2020 International Joint Conference on Neural Networks (IJCNN 2020), 2020, Glasgow, UK. *Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN 2020)*, 2020.



Imagens
224 x 224 x 3



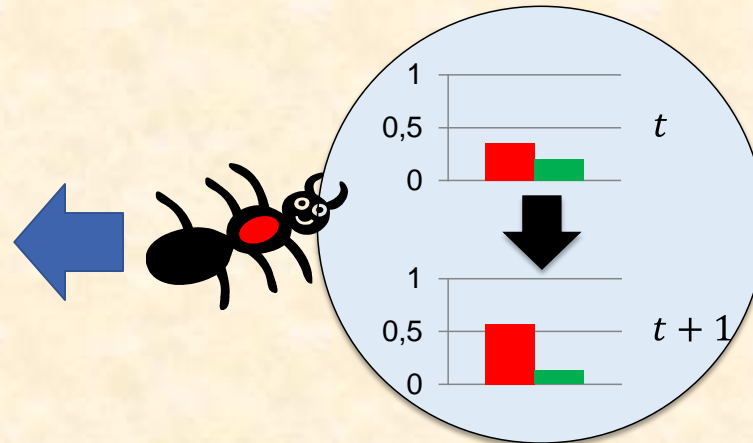
VGG16



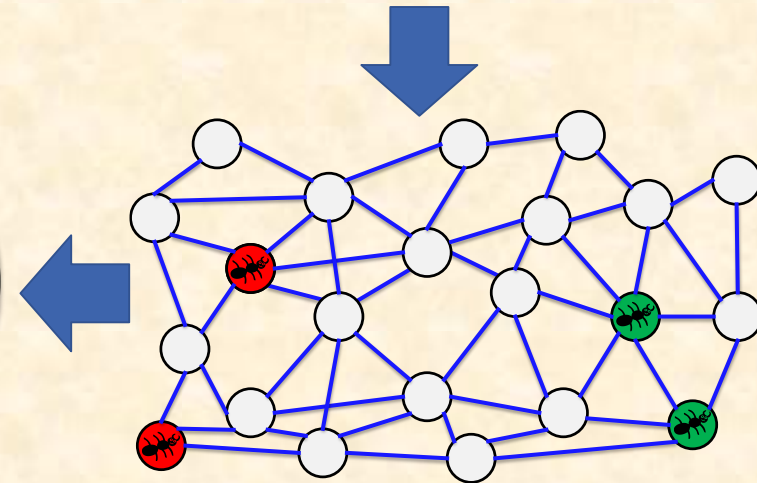
Análise de Componentes Principais



Imagens Classificadas




Competição e Cooperação entre Partículas



Grafo Sem Peso Não Direcionado

Código-Fonte

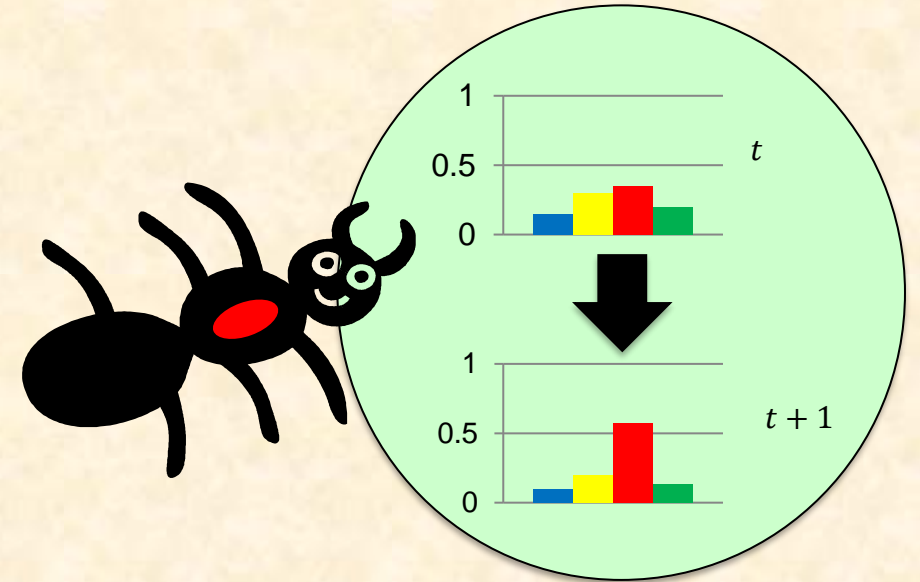
- Python + MATLAB
 - <https://github.com/fbreve/via-py>
- Conjunto de Dados:
 - <https://github.com/fbreve/via-dataset>



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, mostrando ser uma abordagem de aprendizado bastante promissora;
 3. Tem capacidade de se adaptar a mudanças de conceitos graduais ou incrementais, se apresentando como um algoritmo passivo, de classificador único, que se adapta naturalmente à mudanças, sem necessidade de mecanismos explícitos de detecção;

Conclusões

4. Tem capacidade de indicar nós para serem rotulados em tempo de execução e incorporar naturalmente novas informações de rótulos para melhorar a classificação.
5. Tem se mostrado bastante promissor na tarefa de segmentação de imagens, obtendo resultados comparáveis ao de métodos do estado da arte.

RIBEIRO PASSERINI, Jefferson Antonio; BREVE, Fabricio Aparecido. **Complex Network Construction for Interactive Image Segmentation using Particle Competition and Cooperation: A New Approach** In: The 20th International Conference on Computational Science and its Applications (ICCSA2020), 2020, Cagliari, Itália. *Lecture Notes in Computer Science (LNCS)*. Cham, Suíça: Springer International Publishing AG, 2020.



Fig. 5. Images segmentation results by the proposed model with the use of the cut polygon tool and the reference model. Misclassified pixels are highlighted in red. (Color figure online)

Impacto do modelo de Partículas

- Google Acadêmico (até 25/05/2025)
 - 120 citações do artigo original.
 - mais de 200 citações de artigos com extensões e aplicações¹.
- Aplicado em mais de 60 trabalhos publicados¹.
 - 5 Artigos Completos em Periódicos Nacionais e Internacionais.
 - *IEEE Transactions on Knowledge and Data Engineering*
 - *Neurocomputing*
 - *Soft Computing*
 - 18 Artigos Completos em Conferências Nacionais e Internacionais.
 - 28 Resumos em Conferências Nacionais.
 - 8 Teses e Dissertações.
 - 5 Trabalhos de Conclusão de Curso.

¹ foram contabilizados apenas os trabalhos produzidos ou orientados pelo primeiro autor do artigo original.

Particle competition and cooperation in networks for semi-supervised learning

F Breve, L Zhao, M Quiles... - IEEE Transactions on ..., 2011 - ieeexplore.ieee.org
... based on **particle competition** and **cooperation** in the ... **particle competition**-collaboration approach and it has a local spreading fashion in the network, ie, at each time step, each **particle** ...
☆ Salvar Citar Citado por 115 Artigos relacionados Todas as 13 versões

[HTML] Fuzzy community structure detection by **particle competition** and **cooperation**

F Breve, L Zhao - Soft Computing, 2013 - Springer
... introduce the **particle competition** and **cooperation** algorithm. ... For each labeled data item, a corresponding **particle** is ... As the system runs, each **particle** uses a random-greedy rule ...
☆ Salvar Citar Citado por 28 Artigos relacionados Todas as 14 versões

[HTML] **Particle competition** and **cooperation** for semi-supervised learning with label noise

FA Breve, L Zhao, MG Quiles - Neurocomputing, 2015 - Elsevier
... **cooperation** occurs among particles with the same label. This paper presents a new **particle competition** and **cooperation** ... by previous **particle competition** and **cooperation** algorithms ...
☆ Salvar Citar Citado por 23 Artigos relacionados Todas as 15 versões

Interactive image segmentation using **particle competition** and **cooperation**

F Breve, MG Quiles, L Zhao - 2015 international joint ..., 2015 - ieeexplore.ieee.org
... [15], the **particle competition** and **cooperation** approach spread ... new approach, **particle competition** and **cooperation** was ... In this paper, the **particle competition** and **cooperation** model ...
☆ Salvar Citar Citado por 13 Artigos relacionados Todas as 6 versões

Visually impaired aid using convolutional neural networks, transfer learning, and **particle competition** and **cooperation**

F Breve, CN Fischer - 2020 International Joint Conference on ..., 2020 - ieeexplore.ieee.org
... The graph-based SSL method, known as **particle competition** and **cooperation**, is also used for classification, allowing feedback from the user to be incorporated without retraining the ...
☆ Salvar Citar Citado por 10 Artigos relacionados Todas as 9 versões

[PDF] Auto feature weight for interactive image segmentation using **particle competition** and **cooperation**

FA Breve - Proceedings-XI Workshop de Viso Computacional ..., 2015 - fabriciobreve.com
Particle competition and **cooperation** (PCC) is a graph-based semi-supervised learning algorithm. It employs particles walking in a graph to classify data items corresponding to graph ...
☆ Salvar Citar Citado por 4 Artigos relacionados

[PDF] Analysis of the influence of distance metrics on the semi-supervised algorithm of **particle competition** and **cooperation**

L Guerreiro, FA Breve - Proceedings-XI Workshop de Visao ..., 2015 - fabriciobreve.com
... The **Particle Competition** and **Cooperation** in Networks algorithm is one of the techniques in this field, which has always used the Euclidean distance to measure the similarity between ...
☆ Salvar Citar Citado por 4 Artigos relacionados

Particle competition and **cooperation** in networks for semi-supervised learning with concept drift

F Breve, L Zhao - The 2012 International Joint Conference on ..., 2012 - ieeexplore.ieee.org
... Recently, a **particle competition** and **cooperation** approach was used to realize graph-based semi-supervised learning from static data. In this paper, we extend that approach to handle ...
☆ Salvar Citar Citado por 16 Artigos relacionados Todas as 12 versões

Artigos Completos Publicados em Periódicos



1. 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.
2. RIBEIRO DA SILVA, Bárbara; BREVE, Fabricio Aparecido. **Segmentação de imagens utilizando competição e cooperação entre partículas.** *Interciência & Sociedade - Revista Eletrônica*. v.4, p.75 - 85, 2015.

3. BODO, Leandro; OLIVEIRA, Hilda Carvalho; BREVE, Fabricio Aparecido; MARINHO, Eraldo Pereira; ELER, Danilo Medeiros. **Aprendizagem de Máquina para Análise de Indicadores na Engenharia de Software.** *Interciência & Sociedade - Revista Eletrônica*. v.4, p.9 - 20, 2015.








4. BREVE, Fabricio Aparecido; ZHAO, Liang. **Fuzzy community structure detection by particle competition and cooperation.** *Soft Computing (Berlin. Print)*. , v.17, p.659 - 673, 2013.



5. 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 (Print)*, v.24, p.1686 - 1698, 2012.

Artigos Completos Publicados em Anais de Eventos

6. RIBEIRO PASSERINI, Jefferson Antonio; BREVE, Fabricio Aparecido. **Complex Network Construction for Interactive Image Segmentation using Particle Competition and Cooperation: A New Approach** In: The 20th International Conference on Computational Science and its Applications (ICCSA2020), 2020, Cagliari, Itália. *Lecture Notes in Computer Science (LNCS)*. Cham, Suíça: Springer International Publishing AG, 2020. 
7. BREVE, Fabricio Aparecido; FISCHER, Carlos Norberto. **Visually Impaired Aid using Convolutional Neural Networks, Transfer Learning, and Particle Competition and Cooperation** In: 2020 International Joint Conference on Neural Networks (IJCNN 2020), 2020, Glasgow, UK. *Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN 2020)*, 2020. 
8. 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. ICCSA 2017. Lecture Notes in Computer Science*. Cham: Springer International Publishing AG, 2017. v.10404. p.217 – 231. 
9. BREVE, Fabricio Aparecido; PEDRONETTE, Daniel Carlos Guimarães. **Combined Unsupervised and Semi-Supervised Learning for Data Classification** In: 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP), Vietri sul Mare, Itália. *2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP)*. IEEE, 2016. p.1 - 6. 
10. GUERREIRO, Lucas, BREVE, Fabricio Aparecido. **Analysis of the Influence of Distance Metrics on the Semi-supervised Algorithm of 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.77 - 82.
11. 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.
12. MOREIRA DE SOUZA, Raul, BREVE, Fabricio Aparecido. **Parallelization of the Particle Competition and Cooperation approach for Semi-Supervised Learning** In: XI Workshop de Visão Computacional (WVC2015), 2015, São Carlos, SP, Brasil. *Proceedings - XI Workshop de Visão Computacional WVC'2015*, 2015. p.402 - 406.
13. BODO, Leandro; OLIVEIRA, Hilda Carvalho; BREVE, Fabricio Aparecido; ELER, Danilo Medeiros. **Semi-supervised learning applied to performance indicators in software engineering processes** In: International Conference on Software Engineering Research and Practice (SERP'15), 2015, Las Vegas, Nevada, EUA. *International Conference on Software Engineering Research and Practice (SERP'15)*, 2015. p.255 - 261.
14. 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. 
15. 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. p.134 - 140.

Artigos Completos Publicados em Anais de Eventos

16. 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.
17. 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.
18. 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.
19. BREVE, Fabricio Aparecido, ZHAO, Liang. **Aprendizado de Máquina em Redes Complexas**. In: VIII Best MSc Dissertation/PhD Thesis Contest in Artificial Intelligence (CTDIA 2012), The Brazilian Conference on Intelligent System (BRACIS 2012), 2012, Curitiba, Paraná. *Proceedings of the Brazilian Conference on Intelligent Systems (BRACIS 2012)*, 2012.
20. 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 2012 Brazilian Symposium on Neural Network (SBRN 2012)*, 2012. p.79 - 84.
21. 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.
22. 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.
23. 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.

Resumos Publicados em Anais de Eventos

24. HAMAGUTI, Érika Kayoko; BREVE, Fabricio Aparecido. **Classificação de Hortaliças Maduras a partir de Imagens Digitalizadas** In: XI Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2022), 2022, Bauru, SP. *Anais do XI Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2022)*, 2022.
25. RIBEIRO PASSERINI, Jefferson Antonio.; BREVE, Fabricio Aparecido. **Framework para Auxílio a Deficientes Visuais utilizando Redes Neurais Convolucionais como Extratoras de Características** In: XI Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2022), 2022, Bauru, SP. *Anais do XI Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2022)*, 2022.
26. HAMAGUTI, Érika Kayoko; BREVE, Fabricio Aparecido. **Classificação de Morangos Maduros a Partir de Imagens Digitalizadas** In: XI Jornada Científica e Tecnológica (Jornacitec) 2022, 2022, Botucatu – SP. *Anais eletrônicos da Jornacitec*, 2022.
27. RIBEIRO PASSERINI, J. A. ; BREVE, Fabricio Aparecido . **Auxílio a Deficientes Visuais utilizando Redes Neurais Convolucionais e Competição e Cooperação de Partículas**. In: X Workshop do Programa de Pós-Graduação em Ciência da Computação da Unesp (WPPGCC 2021), 2021, Presidente Prudente. *Anais do X Workshop do Programa de Pós-Graduação em Ciência da Computação da Unesp (WPPGCC 2021)*, 2021.
28. GIROTO MILANI, Thiago; BREVE, Fabricio Aparecido. **Aprendizado de Máquina para Detecção de Spam** In: IX Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2019), 2019, Bauru – SP. *Anais do IX Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2019)*, 2019.
29. OLIVEIRA CARNELOZ, Caio; BREVE, Fabricio Aparecido. **Auxílio no Diagnóstico da Doença de Alzheimer a partir de Imagens de Ressonância Magnética utilizando Competição e Cooperação entre Partículas** In: IX Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2019), 2019, Bauru – SP. *Anais do IX Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP (WPPGCC 2019)*, 2019.
30. RIBEIRO PASSERINI, J. A. ; BREVE, Fabricio Aparecido. **Segmentação Interativa de Imagens usando redes complexas e competição e cooperação de partículas**. In: VIII Workshop do Programa de Pós-Graduação em Ciência da Computação da Unesp (WPPGCC 2018), 2018, São José do Rio Preto. *Anais do VIII Workshop do Programa de Pós-Graduação em Ciência da Computação da Unesp (WPPGCC 2018)*, 2018.
31. FOUZ VALENTE, Bruno; BREVE, Fabricio Aparecido. **Aprendizado Semi-Supervisionado utilizando Competição e Cooperação entre Partículas em Dígrafos** In: XXIX Congresso de Iniciação Científica – CIC, 2017, Rio Claro. *Anais do XXIX Congresso de Iniciação Científica – CIC*, 2017.
32. COSTA LEME RODRIGUES, Thiago; BREVE, Fabricio Aparecido. **Otimização de Parâmetros no Modelo de Competição e Cooperação de Partículas** In: XXIX Congresso de Iniciação Científica – CIC, 2017, Rio Claro. *Anais do XXIX Congresso de Iniciação Científica – CIC*, 2017.
33. RIBEIRO PASSERINI, J. A.; BREVE, Fabricio Aparecido. **Aprendizado Semi-Supervisionado aplicado a Segmentação de Imagens** In: VII Workshop do Programa de Pós-Graduação em Ciência da Computação – UNESP, 2017, Rio Claro. *VII Workshop do Programa de Pós-Graduação em Ciência da Computação – UNESP*, 2017. p.25 – 26.

Resumos Publicados em Anais de Eventos

34. OLIVEIRA CARNELOZ, Caio; BREVE, Fabricio Aparecido. **Classificação Da Doença De Alzheimer A Partir De Imagens De Ressonância Magnética Utilizando Competição E Cooperação Entre Partículas** In: VII Workshop do Programa de Pós- Graduação em Ciência da Computação – UNESP, 2017, Rio Claro. *VII Workshop do Programa de Pós-Graduação em Ciência da Computação – UNESP*, 2017. p.33 – 34.
35. GUERREIRO, Lucas; BREVE, Fabricio Aparecido. **Proposta de Dinâmica de Caminhada no Algoritmo de Competição e Cooperação entre Partículas** In: VII Workshop do Programa de Pós- Graduação em Ciência da Computação – UNESP, 2017, Rio Claro. *VII Workshop do Programa de Pós- Graduação em Ciência da Computação – UNESP*, 2017. p.21 – 22.
36. GUERREIRO, Lucas; BREVE, Fabricio Aparecido. **Definição de Métrica de Distância à Priori no Algoritmo de Competição e Cooperação entre Partículas** In: VI Workshop do Programa de Pós-Graduação em Ciência da Computação, 2016, São José do Rio Preto. *Anais do VI Workshop do Programa de Pós-Graduação em Ciência da Computação*, 2016. p.1 - 2.
37. NEGRETTO, Diego Henrique; BREVE, Fabricio Aparecido; FERRO, Milene; BACCI, Maurício; ANTONIO, Erik Aceiro. **Classification of Enzymes of the Ant *Mycocepurus Goeldii* using the Particle Competition and Cooperation Bioinspired Algorithm** In: III Workshop sobre Insetos Sociais (IUSSI - SecBras), 2016, Rio Claro. *Anais do III Workshop sobre Insetos Sociais (IUSSI - SecBras)*, 2016.
38. NEGRETTO, Diego Henrique; ANTONIO, Erik Aceiro; BACCI, Maurício; FERRO, Milene; BREVE, Fabricio Aparecido. **Semi-Supervised Machine Learning Applied to Medical Diagnostics** In: X-Meeting 2015 - 11th International Conference of the AB3C + Brazilian Symposium of Bioinformatics, 2015, São Paulo. *Anais do X-Meeting 2015 - 11th International Conference of the AB3C + Brazilian Symposium of Bioinformatics*, 2015.
39. GUERREIRO, Lucas; BREVE, Fabricio Aparecido. **Análise da Influência de Métricas de Distância no Algoritmo SemiSupervisionado de Competição e Cooperação entre Partículas** In: V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP, 2015, Bauru - São Paulo. *Anais do V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP*, 2015. p.55 - 56.
40. BODO, Leandro, OLIVEIRA, Hilda Carvalho, BREVE, Fabricio Aparecido, ELER, Danilo Medeiros. **Aprendizado semi-supervisionado para análise de indicadores no desenvolvimento de software** In: V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP, 2015, Bauru - São Paulo. *Anais do V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP*, 2015. p.1 - 2.
41. NEGRETTO, Diego Henrique, BREVE, Fabricio Aparecido. **Comparação de Técnicas de Aprendizado de Máquina Semi-Supervisionado na Bioinformática** In: V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP, 2015, Bauru - São Paulo. *Anais do V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP*, 2015. p.51 - 52.
42. RIBEIRO DA SILVA, Bárbara, BREVE, Fabricio Aparecido. **Competição e Cooperação entre Partículas para Segmentação Interativa de Imagens** In: V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP, 2015, Bauru - São Paulo. *Anais do V WPPGCC2015 - Workshop do Programa de Pós-Graduação em Ciência da Computação da UNESP*, 2015. p.9 - 10.
43. MOREIRA DE SOUZA, Raul; BREVE, Fabricio Aparecido. **Segmentação de Imagens de Satélite Utilizando Aprendizado Semi-Supervisionado** In: XXVI Congresso de Iniciação Científica da UNESP, 2014, Rio Claro. *Anais do XXVI Congresso de Iniciação Científica da UNESP*, 2014.

Resumos Publicados em Anais de Eventos

44. RIBEIRO DA SILVA, Bárbara; BREVE, Fabricio Aparecido. **Aprendizado de máquina aplicado à segmentação interativa de imagens** In: IV Workshop do Programa de Pós-Graduação em Ciência da Computação (WPPGCC2014), 2014, Presidente Prudente. *Anais do IV Workshop do Programa de Pós-Graduação em Ciência da Computação (WPPGCC2014)*, 2014.
45. MOREIRA DE SOUZA, Raul; BREVE, Fabricio Aparecido. **Paralelização do algoritmo de competição e cooperação de partículas** In: XXV Congresso de Iniciação Científica da UNESP, 2013, Rio Claro. *Anais do XXV Congresso de Iniciação Científica da UNESP*, 2013.
46. BREVE, Fabricio Aparecido. **Aprendizado de Máquina em Redes Complexas** In: CBIC Thesis and Dissertation Contest 2013, 2013, Ipojuca - Pernambuco. *Proceedings of the 1st BRICS Countries Congress (BRICS-CCI) and 11th Brazilian Congress (CBIC) on Computational Intelligence*, 2013.
47. SOUZA FERREIRA, Rafael de; BREVE, Fabricio Aparecido. **Classificação semi-supervisionada de dados utilizando competição e cooperação entre partículas** In: XXIV Congresso de Iniciação Científica da Unesp (CIC 2012), 2012, Rio Claro, São Paulo. *Anais do XXIV Congresso de Iniciação Científica da Unesp (CIC 2012)*, 2012.
48. CARTOLANO, Ivan Scaranello; BREVE, Fabricio Aparecido. **Deteção de Comunidades Sobrepostas utilizando Modelos Inspirados pela Natureza** In: XXIV Congresso de Iniciação Científica da Unesp (CIC 2012), 2012, Rio Claro, São Paulo. *Anais do XXIV Congresso de Iniciação Científica da Unesp (CIC 2012)*, 2012.
49. MOREIRA DE SOUZA, Raul; BREVE, Fabricio Aparecido. **Implementacao em GPU de modelos de computacao inspirados pela natureza** In: XXIV Congresso de Iniciação Científica da Unesp (CIC 2012), 2012, Rio Claro, São Paulo. *Anais do XXIV Congresso de Iniciação Científica da Unesp (CIC 2012)*, 2012.
50. MOREIRA DE SOUZA, Raul, BREVE, Fabricio Aparecido. **Implementacao em GPU de modelos de computacao inspirados pela natureza**. In: X Simpósio de Iniciação Científica (SIC 2012), 2012, Rio Claro, São Paulo. *Anais do X Simpósio de Iniciação Científica (SIC 2012)*, 2012.
51. MOREIRA DE SOUZA, Raul, BREVE, Fabricio Aparecido. **Implementacao em GPU de modelos de computacao inspirados pela natureza**. In: Seminario Internacional de Iniciacao Cientifica da Universidade de Sao Paulo (SIICUSP 2012), 2012, São Carlos. *Anais do SIICUSP 2012*, 2012.

Teses e Dissertações

52. BREVE, Fabricio Aparecido. **Aprendizado de Máquina Utilizando Dinâmica Espaço-Temporal em Redes Complexas.** São Carlos: *Universidade de São Paulo*, 2010 (Tese de Doutorado)
53. MILANI, Thiago Giroto. **Aprendizado de Máquina para Detecção de SPAM.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2020. (Dissertação de Mestrado)
54. OLIVEIRA CARNELOZ, Caio. **Auxílio no diagnóstico da doença de Alzheimer a partir de imagens de ressonância magnética utilizando competição e cooperação entre partículas.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2019. (Dissertação de Mestrado)
55. RIBEIRO PASSERINI, Jefferson Antonio. **Segmentação interativa de imagens usando redes complexas e competição e cooperação entre partículas.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2019. (Dissertação de Mestrado)
56. GUERREIRO, Lucas. **Aprendizado Semi-Supervisionado Utilizando Modelos de Caminhada de Partículas em Grafos.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2017. (Dissertação de Mestrado)
57. NEGRETTO, Diego Henrique. **Algoritmos de Aprendizado Semi-Supervisionado Baseados em Grafos Aplicados na Bioinformática.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2016. (Dissertação de Mestrado)
58. BODO, Leandro. **Aprendizagem de Máquina para Análise de Indicadores em Processos de Software.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2015. (Dissertação de Mestrado)
59. RIBEIRO DA SILVA, Bárbara. **Segmentação Interativa utilizando Competição e Cooperação entre Partículas.** Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2015. (Dissertação de Mestrado)

Trabalhos de Conclusão de Curso

60. SCHIO CAMPOS DA SILVA, Carlos Eduardo. **Combinação de Classificadores utilizando Modelo de Competição e Cooperação entre Partículas**. Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2018. (Trabalho de Conclusão de Curso)
61. FOUZ VALENTE, Bruno. **Segmentação Interativa de Imagens utilizando Competição e Cooperação entre Partículas em Dígrafos, Dígrafos Reversos e Grafos com Vizinhança Mútua**. Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2017. (Trabalho de Conclusão de Curso)
62. MOREIRA DE SOUZA, Raul. **Cooperação e Competição de Partículas Rápido: Uma Abordagem para Aprendizado Semi-Supervisionado**. Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2016. (Trabalho de Conclusão de Curso)
63. GUERREIRO, Lucas. **Análise da Influência de Métricas de Distância no Algoritmo Semi-Supervisionado de Competição e Cooperação de Partículas em Redes**. Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2015. (Trabalho de Conclusão de Curso)
64. FARIZELI FIORI, Uriel Alexis. **Deteção de Comunidades utilizando Movimentação de Partículas em Redes Complexas**. Rio Claro: *Universidade Estadual Paulista Júlio de Mesquita Filho*, 2013. (Trabalho de Conclusão de Curso)

Competição e Cooperação entre Partículas em Grafos

Fabricio Breve

www.fabriciobreve.com

