


**Theses and Dissertations Competition (CI/AI TDC)
1st BRICS Countries Congress (BRICS-CCI) and 11th
Brazilian Congress (CBIC) on Computational Intelligence**



Aprendizado de Máquina em Redes Complexas

Fabricio Aparecido Breve¹

Orientador: Prof. Dr. Zhao Liang



Instituto de Ciências Matemáticas e Computação (ICMC)
Universidade de São Paulo (USP), São Carlos-SP
fabricio@rc.unesp.br | zhao@icmc.usp.br



¹ Fabricio Breve trabalha atualmente no Instituto de Geociências e Ciências Exatas (IGCE), Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP)



Agenda

- Introdução
 - Motivações e Objetivos
- Modelos Desenvolvidos
 - Modelos baseados em Redes de Osciladores Acoplados
 - Modelos baseados em Movimentação de Partículas em Redes Complexas
- Conclusões

Introdução

Motivação e Objetivos

Motivações

- Dinâmica em redes
 - A maior parte dos estudos anteriores em redes considera que a rede é uma estrutura estática, poucos consideram dinâmica em redes.
- Sincronização por fase
 - Todos os modelos de segmentação e atenção visual baseados em sincronização entre osciladores encontrados na literatura utilizam apenas sincronização completa.
 - Menos robusta e requer uma força de acoplamento maior que a sincronização por fase.

Motivações

- Modelos dinâmicos
 - A maioria dos algoritmos de aprendizado tem como base modelos estáticos que podem não se adequar a dados cujos grupos ou classes apresentem diferentes formas, densidades e tamanhos.
- Propagação de rótulos local
 - A maioria dos métodos de aprendizado semi-supervisionado baseados em grafos utiliza propagação de rótulos global, resultando em algoritmos de alta complexidade computacional.
- Comunidades sobrepostas
 - Em agrupamento/classificação, nem sempre os elementos pertencem a um único grupo. Há casos em que elementos pertencem a múltiplas comunidades. A maioria dos métodos não consegue detectar tal estrutura de sobreposição.

Objetivos

- Estudar osciladores acoplados em redes.
 - Aplicação em atenção visual.
 - Tarefa importante em visão computacional.
- Estudar sincronização por fase entre osciladores acoplados
 - Tipo de sincronização mais robusto.
 - Requer uma força de acoplamento menor que a sincronização completa.
- Construir técnicas de aprendizado de máquina que:
 - Identifiquem formas arbitrárias de classes/grupos.
 - Revelem a estrutura de sobreposição existente entre elas utilizando dados organizados em redes complexas.
 - Tenham baixa complexidade computacional.

Modelos Desenvolvidos

- 1) Modelos baseados em Redes de Osciladores Acoplados
- 2) Modelos baseados em Movimentação de Partículas em Redes Complexas

Modelos Baseados em Redes de Osciladores Acoplados

- 1) Atenção Visual com Sincronização por Fase em Redes de Osciladores
- 2) Atenção Visual com Sincronização e Dessincronização por Fase em Redes de Osciladores

Aplicação em Atenção Visual

- Características essenciais:
 - Realçar região da imagem para onde foco de atenção é direcionado
 - Suprimir demais regiões da imagem
 - Mudança do foco de atenção para demais regiões ativas
- Biologicamente plausível:
 - Sistemas vivos desenvolveram a capacidade de selecionar apenas informações relevantes do ambiente para alimentar seus sistemas sensoriais
 - Capacidade de processamento limitada do hardware neuronal disponível para muitas tarefas
 - Experimentos neurobiológicos mostram que a atenção visual tem forte ligação com a sincronização entre neurônios

Tsotsos, J. K., Culhane, S. M., Wai, W. Y. K., Lai, Y., Davis, N., & Nuflo, F. (1995). **Modeling visual attention via selective tuning.** *Artificial Intelligence*, 78, 507–545.

Atenção Visual com Sincronização e Dessincronização por Fase em Redes de Osciladores

- Reticulado de osciladores Rössler
- Cada pixel é representado por um oscilador
- Objeto saliente é o que tem o maior contraste com relação aos demais
 - Osciladores do objeto saliente são sincronizados por fase
 - Osciladores dos demais objetos são dessincronizados

Breve, F. A., Zhao, L., Quiles, M. G., & Macau, E. E. N. (2009c). **Chaotic phase synchronization and desynchronization in an oscillator network for object selection.** *Neural Networks*, 22(5-6), 728–737.


Breve, F. A., Zhao, L., Quiles, M. G., & Macau, E. E. N. (2009d). **Chaotic phase synchronization for visual selection.** *IEEE - INNS - ENNS International Joint Conference on Neural Networks*, (pp. 383–390).

Atenção Visual com Sincronização e Dessincronização por Fase em Redes de Osciladores


$$\begin{aligned}\dot{x}_{i,j} &= -\omega_{i,j}y_{i,j} - z_{i,j} + k_{i,j}^+\Delta^+x_{i,j} + k_{i,j}^-\Delta^-x_{i,j}, \\ \dot{y}_{i,j} &= \omega_{i,j}x_{i,j} + ay_{i,j}, \\ \dot{z}_{i,j} &= b + z_{i,j}(x_{i,j} - c).\end{aligned}$$

- k^+ é a força de acoplamento positiva
- k^- é a força de acoplamento negativa
- (i,j) é um ponto na grade
- Intensidade do pixel codificada em ω
- Contraste codificado em k^+ e k^-
- Quatro atributos:
 - Intensidade
 - Componentes RGB

- **Conexões positivas são mantidas para pixels com cores semelhantes e cortadas para pixels com cores diferentes**







- **Conexões negativas estão sempre ligadas**






Atenção Visual com Sincronização e Dessincronização por Fase em Redes de Osciladores

- Estratégia de atenção visual
 - Pixels com maior contraste
 - Força de acoplamento negativa tende a zero e não afeta sincronização
 - Força de acoplamento positiva mantém osciladores sincronizados
 - Pixels com menor contraste
 - Força de acoplamento negativa é mais forte e faz osciladores repelirem uns aos outros
 - *Apenas osciladores correspondendo ao objeto saliente irão permanecer com suas trajetórias sincronizadas em fase, enquanto que outros objetos terão suas trajetórias com fases diferentes.*







(a) Imagem artificial com alto contraste; (b) Comportamento dos osciladores;
(c) Crescimento de fase; (d) Séries temporais do desvio-padrão de fase de cada objeto;






$$R_{i,j} = \exp\left(-\frac{(1 - C_{i,j})^2}{2\sigma^2}\right)$$

Mais uma vez é necessário
diminuir σ para compensar o
menor contraste

(a) Imagem artificial com baixo contraste; (b) Comportamento dos osciladores, $\sigma=0,25$;
(c) Crescimento de fase, $\sigma=0,25$.




(a) Imagem artificial com baixo contraste; (b) Comportamento dos osciladores, $\sigma=0,10$;
(c) Crescimento de fase, $\sigma=0,10$.






Atenção visual com imagem real - “Flor Gloxínia”: (a) Imagem fonte; (b) Comportamento dos osciladores; (c) Crescimento de fase; (d) Séries temporais do desvio padrão de fase de cada objeto.

Mudança de Foco de Atenção




Atenção visual em imagem artificial - “Espirais”: (a) Imagem fonte; (b) Comportamento dos osciladores; (c) Séries temporais do desvio padrão de fase de cada objeto.





Atenção visual em imagem real
 - “Cachorro”: (a) Imagem
 fonte; (b) Comportamento dos
 osciladores; (c) Séries
 temporais do desvio padrão de
 fase de cada objeto.



Modelos baseados em Movimentação de Partículas em Redes Complexas


- 1) Detecção de Comunidades Sobrepostas em Redes Complexas com Competição de Partículas
- 2) Aprendizado Semi-Supervisionado em Redes Complexas com Competição e Cooperação entre Partículas

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

- Competição e cooperação entre partículas na rede, combinadas 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 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 configurado para seus respectivos times.
 - Ex: **[1 0 0 0]** (4 classes, nó rotulado como classe A)
 - Nós não rotulados tem níveis de domínio configurados igualmente para cada time.
 - Ex: **[0.25 0.25 0.25 0.25]** (4 classes, nó não rotulado)



$$v_i^{\omega_\ell} = \begin{cases} 1 & \text{se } y_i = \ell \\ 0 & \text{se } y_i \neq \ell \text{ e } y_i \in L \\ 1/c & \text{se } y_i = \emptyset \end{cases}$$

Dinâmica de nós

- Quando uma partícula seleciona um vizinho para visitar, ela...
 - Diminui o nível de domínio de outros times no nó alvo.
 - Aumenta o nível de domínio de seu próprio time no nó alvo.
- Exceção:
 - Níveis de domínio de nós rotulados são fixos.



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

Dinâmica de Partículas

- Uma partícula se torna:
 - Mais forte quando ela tem como alvo um nó dominado por seu time
 - Mais fraca quando ela tem como alvo 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


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

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






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 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

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







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.





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







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






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





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	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



Erros de teste de classificação (%) utilizando 10 pontos de dados rotulados

	<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


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

- Detecção de nós sobrepostos
- Detecção de *outliers*



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

- Detecção de nós sobrepostos. As cores indicam índice de sobreposição detectados pelo método proposto.



Conclusões

Conclusões, Principais Contribuições e Publicações Geradas

Conclusões

- A **combinação de dinâmica e estrutura** se mostrou uma abordagem bastante adequada para tratamento dos problemas computacionais abordados nessa tese.
 - A continuidade deste estudo poderá trazer novas soluções para outros problemas computacionais e outros problemas relacionados com sistemas complexos.
- O uso da **sincronização por fase** – mais robusta – além de biologicamente plausível, pode oferecer uma boa contribuição em sistemas de análise de dados (padrões) baseados em sincronização de sistemas caóticos acoplados.
- A abordagem inédita de construção de um sistema que combina **tarefas de segmentação e atenção visual em um único passo**, tem importância teórica e prática, pois oferece um novo caminho no desenvolvimento de sistemas de visão computacional.

Conclusões

- O mecanismo de **competição e cooperação entre partículas em redes** complexas oferece um caminho alternativo para o desenvolvimento de redes neurais artificiais, que considera a estrutura dos dados de entrada.
- A abordagem de partículas se mostrou bastante eficaz na **detecção de nós sobrepostos**, oferecendo novas possibilidades de tratamento de dados que apresentem tais estruturas.
- A estratégia de competição e cooperação entre partículas é diferente de todas as técnicas tradicionais de aprendizado semi-supervisionado, apresentando **bom desempenho de classificação, baixa complexidade computacional**, e possibilidade de **detectar outliers** e **evitar a propagação de erros** vinda dos mesmos.
 - É uma abordagem de aprendizado bastante promissora, e abre caminho para o desenvolvimento de outras técnicas inspiradas na natureza.

Conclusões

- Principais Contribuições
 - Novos modelos de atenção visual, utilizando pela primeira vez a sincronização por fase entre sistemas caóticos;
 - Novos modelos de atenção visual que realizam a segmentação de um objeto ao mesmo tempo em que direcionam a ele o foco de atenção;
 - Nova técnica de agrupamento de dados, com capacidade de detectar sobreposição entre grupos e fornecer graus de pertinência à cada grupo por cada elemento;
 - Nova técnica de aprendizado semi-supervisionado, com desempenho comparável ao de técnicas do estado da arte, além de complexidade computacional inferior a de muitos outros modelos baseados em grafos, e abordagem fundamentalmente diferente das demais;
 - Nova técnica de aprendizado semi-supervisionado capaz de detectar sobreposição entre classes e minimizar a propagação de erros provenientes de outliers.

Publicações

- Artigos publicados em **periódicos internacionais** que tiveram a participação do doutorando como autor ou co-autor:

QUALIS
A1

1. 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.

QUALIS
A1

2. BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves; MACAU, Elbert Einstein Nehrer. **Chaotic Phase Synchronization and Desynchronization in an Oscillator Network for Object Selection. *Neural Networks***, v. 22, p. 728-737, 2009.

QUALIS
A1

3. QUILES, Marcos Gonçalves; ZHAO, Liang; BREVE, Fabricio Aparecido; ROMERO, Roseli Aparecida Francelin. **A network of integrate and fire neurons for visual selection. *Neurocomputing* (Amsterdam)**, v. 72, p. 2198-2208, 2009.

QUALIS
A1

4. ZHAO, Liang; BREVE, Fabricio Aparecido. **Chaotic synchronization in 2D lattice for scene segmentation. *Neurocomputing* (Amsterdam)**, v. 71, p. 2761-2771, 2008.

Publicações

- Artigos publicados em **conferências nacionais e internacionais** que tiveram a participação do doutorando como autor ou co-autor:

QUALIS
A2

1. 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.

QUALIS
A2

2. QUILES, Marcos Gonçalves; ZHAO, Liang ; BREVE, Fabricio Aparecido; Rocha, Anderson de Rezende. **Label Propagation Through Neuronal Synchrony**. 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. 2517-2524.

3. QUILES, Marcos Gonçalves; ZHAO, Liang; BREVE, Fabricio Aparecido. **A Network of Integrate and Fire Neurons for Community Detection in Complex Networks**. In: Brazilian Conference on Dynamics, Control and Their Applications, 2010, Serra Negra, São Paulo. **Brazilian Conference on Dynamics, Control and Their Applications**, 2010.

4. BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves. **Particle Competition in Complex Networks for Semi-Supervised Classification**. In: The First International Conference on Complex Sciences: Theory and Applications (Complex'2009), 2009, Shanghai. **Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering (LNICST)**. Heidelberg Berlin : Springer-Verlag, 2009. v. 4. p. 163-174.

QUALIS
A2

5. BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves; MACAU, Elbert Einstein Nehrer. **Chaotic phase synchronization for visual selection**. In: *International Joint Conference on Neural Networks, 2009, Atlanta, Georgia, USA. Proceedings of 2009 International Joint Conference on Neural Networks (IJCNN2009)*. Los Alamitos, California : IEEE Computer Society, 2009. p. 383-390.

Publicações

- Artigos publicados em **conferências nacionais e internacionais** que tiveram a participação do doutorando como autor ou co-autor:

QUALIS
B4

6. QUILLES, Marcos Gonçalves; ZHAO, Liang; BREVE, Fabricio Aparecido; ROMERO, Roseli Aparecida Francelin. **Detecção de comunidades em redes complexas: um modelo de correlação oscilatória**. In: VII Encontro Nacional de Inteligência Artificial (ENIA), 2009, Bento Gonçalves, RS. *Anais do XXIX Congresso da Sociedade Brasileira de Computação*, 2009. p. 889-898.
7. BREVE, Fabricio Aparecido; ZHAO, Liang; QUILLES, Marcos Gonçalves. **Uncovering Overlap Community Structure in Complex Networks Using Particle Competition**. In: The 2009 International Conference on Web Information Systems and Mining (WISM 09) and the 2009 International Conference on Artificial Intelligence and Computational Intelligence (AICI'09), 2009, Shanghai, China. *Lecture Notes in Computer Science, Artificial Intelligence and Computational Intelligence*. Berlin / Heidelberg : Springer-Verlag, 2009. v. 5855. p. 619-628.

QUALIS
B4

8. QUILLES, Marcos Gonçalves; BREVE, Fabricio Aparecido; ROMERO, Roseli Aparecida Francelin; ZHAO, Liang. **Visual Selection with Feature Contrast-Based Inhibition in a Network of Integrate and Fire Neurons**. In: The 4 th International Conference on Natural Computation (ICNC'08) and the 5 th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'08), 2008, Jinan, Shandong. *Proceedings of The 4 th International Conference on Natural Computation (ICNC'08) and the 5 th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'08)*, 2008. Los Alamitos, CA, USA : IEEE Computer Society, 2008. v. 3. p. 601-605.

QUALIS
B4

9. ZHAO, Liang; BREVE, Fabricio Aparecido; QUILLES, Marcos Gonçalves; ROMERO, Roseli Aparecida Francelin. **Visual Selection and Shifting Mechanisms Based on a Network of Chaotic Wilson-Cowan Oscillators**. In: The 3rd International Conference on Natural Computation (ICNC'07) and the 4th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'07), 2007, Haikou. *Proceedings of The 3rd International Conference on Natural Computation (ICNC'07) and the 4th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'07)*. Los Alamitos, California : IEEE Computer Society, 2007. v. 5. p. 754-759.

QUALIS
B2

10. QUILLES, Marcos Gonçalves; BREVE, Fabricio Aparecido; ZHAO, Liang; ROMERO, Roseli Aparecida Francelin. **A Visual Selection Mechanism Based on Network of Chaotic Wilson-Cowan Oscillators**. In: International Conference on Intelligent Systems Design and Applications, 2007, Rio de Janeiro. *Proceedings of the Seventh International Conference on Intelligent Systems Design and Applications ISDA 2007*. Los Alamitos, California : IEEE Computer Society, 2007. p. 919-924.

Publicações

- Artigos publicados pelo autor a partir de trabalhos derivados da tese de doutorado:

QUALIS
A2

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

2. 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.

QUALIS
B5

3. BREVE, Fabricio Aparecido ; ZHAO, Liang . **Preventing Error Propagation in Semi-Supervised Learning Using Teams of Walking Particles**. In: X Congresso Brasileiro de Inteligência Computacional (CBIC'11), 2011, Fortaleza, Ceará. *Anais do X Congresso Brasileiro de Inteligência Computacional (CBIC'11)*, 2011.

QUALIS
A2

4. BREVE, Fabricio Aparecido ; ZHAO, Liang . **Particle Competition and Cooperation in Networks for Semi-Supervised Learning with Concept Drift**. In: The 2012 International Joint Conference on Neural Networks (IJCNN), 2012, Brisbane, Australia. *The 2012 International Joint Conference on Neural Networks (IJCNN)*, 2012. p. 1803-1808.

QUALIS
B3

5. 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.

QUALIS
A2

6. 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.

QUALIS
B5

7. 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.

QUALIS
B5

8. 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.


**Theses and Dissertations Competition (CI/AI TDC)
1st BRICS Countries Congress (BRICS-CCI) and 11th
Brazilian Congress (CBIC) on Computational Intelligence**



Aprendizado de Máquina em Redes Complexas

Fabricio Aparecido Breve¹

Orientador: Prof. Dr. Zhao Liang



Instituto de Ciências Matemáticas e Computação (ICMC)
Universidade de São Paulo (USP), São Carlos-SP
fabricio@rc.unesp.br | zhao@icmc.usp.br



¹ Fabricio Breve trabalha atualmente no Instituto de Geociências e Ciências Exatas (IGCE), Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP)

