

# Aprendizado de Máquina em Redes Complexas

**Fabricio Aparecido Breve**  
**Orientador: Prof. Dr. Zhao Liang**

# Agenda

- Introdução
  - Motivações e Objetivos
- Revisão Bibliográfica
  - Redes Complexas
  - Aprendizado de Máquina
  - Sistemas Dinâmicos
- Modelos Desenvolvidos
  - Modelos baseados em Redes de Osciladores Acoplados
  - Modelos baseados em Movimentação de Partículas em Redes Complexas
- Conclusões

# Introdução

---

Motivação e Objetivos

# Motivações

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

# Motivações

- 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.
- A maioria dos métodos de aprendizado semi-supervisionado baseados em grafos utiliza propagação de rótulos global, resultando em algoritmos de alta complexidade computacional.
- 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 e aplicação em atenção visual, a qual é uma tarefa importante em visão computacional.
- Estudar sincronização por fase entre osciladores acoplados, um tipo de sincronização mais robusto e que requer uma força de acoplamento menor que a sincronização completa.
- Construir técnicas de aprendizado de máquina capazes de identificar formas arbitrárias de classes/grupos e também de revelar a estrutura de sobreposição existente entre elas utilizando dados organizados em redes complexas, preferencialmente com baixa complexidade computacional.

# Revisão Bibliográfica

---

- 1) Redes Complexas
- 2) Aprendizado de Máquina
- 3) Sistemas Dinâmicos

# Redes Complexas

- Redes complexas são redes de grande escala com padrões de conexões não triviais.
- Mudança no foco de estudos:
  - **Antes:** análise de grafos pequenos
  - **Atual:** estudo de propriedades estatísticas de grafos de larga escala
- Disponibilidade de computadores e redes de comunicação que permitem analisar dados em uma escala muito maior do que era possível anteriormente.
- Redes analisadas cada vez maiores:
  - Internet, a World Wide Web (WWW), sistemas de telecomunicações, redes de energia elétrica, redes sociais, redes de tráfego, redes biológicas, como redes neurais, redes de interação entre proteínas, etc.



# 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.
- Principais categorias:
  - Aprendizado Supervisionado
  - **Aprendizado Não Supervisionado**
  - **Aprendizado Semi-Supervisionado**

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

# Aprendizado Não Supervisionado

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

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

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

# 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. (2005). *Semi-Supervised Learning Literature Survey*. Technical Report 1530, Computer Sciences, University of Wisconsin-Madison.

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

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

# Sistemas Dinâmicos


- Tem suas origens na mecânica Newtoniana
- Pode ser definido como uma fórmula matemática que descreve a evolução de estados de um sistema no decorrer do tempo
- O tempo pode ser uma variável:
  - Contínua
    - equação diferencial
  - Discreta
    - equação diferença
- Para determinar o estado para todos os tempos futuros é necessário iterar essa relação muitas vezes, cada uma avançando um pequeno espaço no tempo

$$\dot{\mathbf{x}} = F(\mathbf{x}, \mu)$$
$$\mathbf{x}(t_0) = \mathbf{x}_0$$

$$\mathbf{x}(t + 1) = F(\mathbf{x}(t), \mu),$$
$$\mathbf{x}(0) = \mathbf{x}_0$$

# Dinâmica Caótica

- É um fenômeno produzido por sistemas dinâmicos
- Um sistema caótico tem as seguintes características:
  - Limitado
  - Não Periódico
  - Determinístico
  - Sensível a condição inicial



Dois pontos inicialmente próximos terão trajetórias totalmente diferentes com o decorrer do tempo (efeito borboleta). **Exemplo:** Mapa Logístico com  $a = 4,0$ ,  $x_1(0) = 0,1$  e  $x_2(0) = 0,100001$

# Sincronização em Sistemas Dinâmicos

- Sistemas caóticos tem comportamento imprevisível a longo prazo
- Porém é possível forçar dois sistemas caóticos a se “travarem” um ao outro e permanecerem sincronizados
  - Através da utilização de um sinal condutor comum ou através de um acoplamento
- Existem diferentes tipos de sincronização:
  - Sincronização Completa
  - **Sincronização por Fase**
  - Etc.



# Sincronização por Fase

- Obtida quando existe uma perfeita sincronização das fases de subsistemas oscilatórios utilizando uma pequena força de acoplamento (em relação à força utilizada na sincronização completa), enquanto as amplitudes podem permanecer não relacionadas
- Sejam dois osciladores caóticos com fases definidas por  $\phi_1$  e  $\phi_2$ . Dizemos que ambos estão sincronizados se a diferença entre suas respectivas fases  $|\phi_1 - \phi_2|$  for limitada, por exemplo:  $|\phi_1 - \phi_2| < M$ , conforme  $t \rightarrow \infty$

# Sincronização por Fase

- Exemplo: dois osciladores Rössler acoplados:

$$\dot{x}_1 = -\omega_1 y_1 - z_1 + k(x_2 - x_1),$$

$$\dot{y}_1 = \omega_1 x_1 + a y_1,$$

$$\dot{z}_1 = b + z_1(x_1 - c),$$

$$\dot{x}_2 = -\omega_2 y_2 - z_2 + k(x_1 - x_2),$$


$$\dot{y}_2 = \omega_2 x_2 + a y_2,$$

$$\dot{z}_2 = b + z_2(x_2 - c),$$

onde  $\omega_1$  e  $\omega_2$  governam a frequência de cada um dos osciladores, e  $k$  é a força de acoplamento.



# Sincronização por Fase



Diferença de fase entre dois Osciladores de Rössler acoplados ao longo do tempo mostrando o regime não sincronizado ( $k = 0,01$ ), quase sincronizado ( $k = 0,036$ ) e sincronizado ( $k = 0,045$ ).  $\Delta\omega = 0,040$  ( $\omega_1 = 0,980$ ,  $\omega_2 = 1,020$ ).

# 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 por Fase em Redes de Osciladores

- Reticulado de osciladores Rössler
- Cada pixel da imagem corresponde a um oscilador
  - Osciladores são acoplados quando a diferença entre pixels está abaixo de um limiar



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

Intensidade do pixel codificada em  $\omega$

$$\begin{aligned}\Delta^{\pm}x_{i,j} = & \gamma_{i-1,j-1;i,j}(x_{i-1,j-1} - x_{i,j}) + \\ & \gamma_{i-1,j;i,j}(x_{i-1,j} - x_{i,j}) + \\ & \gamma_{i-1,j+1;i,j}(x_{i-1,j+1} - x_{i,j}) + \\ & \gamma_{i,j-1;i,j}(x_{i,j-1} - x_{i,j}) + \\ & \gamma_{i,j+1;i,j}(x_{i,j+1} - x_{i,j}) + \\ & \gamma_{i+1,j-1;i,j}(x_{i+1,j-1} - x_{i,j}) + \\ & \gamma_{i+1,j;i,j}(x_{i+1,j} - x_{i,j}) + \\ & \gamma_{i+1,j+1;i,j}(x_{i+1,j+1} - x_{i,j}),\end{aligned}$$

# Atenção Visual com Sincronização por Fase em Redes de Osciladores

- Objeto mais brilhante terá maior crescimento de fase
- Mecanismo de atenção é implementado aumentando a frequência de oscilação, através de incremento no parâmetro  $\omega$
- Objeto saliente passa de dinâmica caótica para periódica e crescimento de fase maior que os demais








Diagrama de bifurcação de um oscilador Rössler variando o parâmetro  $\omega$





Atividades temporais de osciladores Rössler com  $\omega=0,8$ ;  $\omega=0,9$ ;  $\omega=1,0$ ;  $\omega=2,0$ ; e  $\omega=4,5$  respectivamente.




Atenção visual em imagem artificial com 5 objetos linearmente não separáveis (incluindo o fundo), 25 x 25 pixels: (a) Imagem original; (b) Medida de fase dos blocos de osciladores. Cada trajetória na figura representa um grupo de osciladores sincronizados por fase e corresponde a um segmento da imagem de entrada; (c) Atividades temporais dos blocos de osciladores. Cada linha na figura corresponde a um objeto da imagem de entrada. A escala vertical do segundo ao quinto objeto está deslocada para baixo em 40.







Atenção visual em imagem artificial com 7 segmentos, 80x60 pixels: (a) Imagem original; (b) Medida de fase dos blocos de osciladores. Cada trajetória na figura representa um grupo de osciladores sincronizados por fase e corresponde a um segmento da imagem de entrada; (c) Atividades temporais dos blocos de osciladores, cada linha na figura corresponde a um objeto da imagem de entrada, a escala vertical do segundo ao sétimo objeto está deslocada para baixo em 40.



# 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  $\omega$
- 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.*
  - **Mudança de foco** é implementada através de um contraste relativo que é a convolução entre o contraste absoluto e uma função gaussiana variando no tempo.





(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;







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

O contraste relativo  $R$  é calculado por uma função Gaussiana, onde  $\sigma$  define sua abertura. Nesse caso precisamos diminuir  $\sigma$  para compensar o menor contraste




(a) Imagem artificial com médio contraste; (b) Comportamento dos osciladores,  $\sigma=0,4$ ;  
(c) Crescimento de fase,  $\sigma=0,4$ .





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




# Detecção de Comunidades Sobrepostas em Redes Complexas com Competição de Partículas

- Competição entre partículas pelos nós da rede
- Cada partícula tenta possuir a maior quantidade possível de nós
- Caminhada Aleatório-Gulosa

Breve, F. A., Zhao, L., & Quiles, M. G. (2009b). **Uncovering overlap community structure in complex networks using particle competition.** In *International Conference on Artificial Intelligence and Computational Intelligence (AICI'09)*, volume 5855 (pp. 619–628).

# Configuração Inicial

- É criada uma partícula para cada grupo da rede
- A posição inicial de cada partícula é ajustada aleatoriamente
- Cada nó tem um conjunto de níveis de domínio, um correspondendo a cada partícula, inicializados todos com mesmo valor e soma igual a 1




Ex: [ 0.25 0.25 0.25 0.25 ]  
(4 grupos/partículas)

$$v_i^{\omega_j}(0) = \omega_{\min} + \left( \frac{\omega_{\max} - \omega_{\min}}{c} \right)$$

# Dinâmica de Nós


- Quando uma partícula seleciona um nó para visitar
  - Ela diminui o nível de domínio de outras partículas
  - Ela aumenta o seu próprio nível de domínio



$$v_i^{\omega_k}(t+1) = \begin{cases} \max\{\omega_{\min}, v_i^{\omega_k}(t) - \frac{\Delta v \rho_j^{\omega}(t)}{c-1}\} \\ v_i^{\omega_k}(t) + \sum_{q \neq k} v_i^{\omega_q}(t) - v_i^{\omega_q}(t+1) \end{cases}$$

# Dinâmica de Partículas

- Uma partícula se torna
  - Mais forte quando escolhe um nó dominado por ela mesma
  - Mais fraca quando escolhe um nó dominado por outra partícula



$$\rho_j^\omega(t+1) = \rho_j^\omega(t) + \Delta_\rho(v_i^{\omega j}(t+1) - \rho_j^\omega(t))$$

# Caminhada Aleatório-Gulosa

- Caminhada Aleatória

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

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


- Caminhada Gulosa

- A partícula prefere visitar nós que ela já domina
- Probabilidade dada pelo nível de domínio


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

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



---

**Algoritmo 4.1:** Detecção de comunidades sobrepostas com competição de partículas

---

- 1 Construa a matriz de adjacência  $W$  usando a Equação (4.1) ;
  - 2 Configure os níveis de domínio usando a Equação (4.4) e a Equação (4.5) ;
  - 3 Configure a posição inicial das partículas aleatoriamente e configure seus potenciais usando a Equação (4.6) ;
  - 4 **repita**
    - 5 Selecione o nó alvo para cada partícula usando a Equação (4.8) ou a Equação (4.7) para o movimento determinístico ou aleatório respectivamente ;
    - 6 Atualize os níveis de domínio dos nós usando a Equação (4.9) ;
    - 7 **se** o movimento aleatório foi escolhido **então**
      - 8 Atualize os níveis de domínio de longo prazo usando a Equação (4.11) ;
    - 9 Atualize os potenciais das partículas usando a Equação (4.10) ;
  - 10 **até** convergência ou por um número pré-definido de passos;
  - 11 Calcule os níveis de pertinência (classificação nebulosa) usando a Equação (4.12) ;
-

# Detecção de Comunidades Sobrepostas em Redes Complexas com Competição de Partículas

- Classificação nebulosa de um nó conectado em uma rede com 4 comunidades e baixa mistura ( $z_{\text{out}} / \langle k \rangle = 0,125$ )

| Conexões | Classificação Nebulosa |        |        |        |
|----------|------------------------|--------|--------|--------|
| A-B-C-D  | A                      | B      | C      | D      |
| 16-0-0-0 | 0,9928                 | 0,0017 | 0,0010 | 0,0046 |
| 15-1-0-0 | 0,9210                 | 0,0646 | 0,0079 | 0,0065 |
| 14-2-0-0 | 0,8520                 | 0,1150 | 0,0081 | 0,0248 |
| 13-3-0-0 | 0,8031                 | 0,1778 | 0,0107 | 0,0084 |
| 12-4-0-0 | 0,7498                 | 0,2456 | 0,0032 | 0,0014 |
| 11-5-0-0 | 0,6875                 | 0,3101 | 0,0016 | 0,0008 |
| 10-6-0-0 | 0,6211                 | 0,3577 | 0,0111 | 0,0101 |
| 9-7-0-0  | 0,5584                 | 0,4302 | 0,0011 | 0,0103 |
| 8-8-0-0  | 0,4949                 | 0,4944 | 0,0090 | 0,0017 |
| 8-4-4-0  | 0,5025                 | 0,2493 | 0,2461 | 0,0021 |
| 7-4-4-1  | 0,4397                 | 0,2439 | 0,2491 | 0,0672 |
| 6-4-4-2  | 0,3694                 | 0,2501 | 0,2549 | 0,1256 |
| 5-4-4-3  | 0,3144                 | 0,2491 | 0,2537 | 0,1828 |
| 4-4-4-4  | 0,2512                 | 0,2506 | 0,2504 | 0,2478 |


# Detecção de Comunidades Sobrepostas em Redes Complexas com Competição de Partículas

- Classificação nebulosa de um nó conectado em uma rede com 4 comunidades e alta mistura ( $z_{\text{out}} / \langle k \rangle = 0,375$ )

| Conexões | Classificação Nebulosa |        |        |        |
|----------|------------------------|--------|--------|--------|
| A-B-C-D  | A                      | B      | C      | D      |
| 16-0-0-0 | 0,9709                 | 0,0092 | 0,0108 | 0,0091 |
| 15-1-0-0 | 0,9160                 | 0,0647 | 0,0093 | 0,0101 |
| 14-2-0-0 | 0,8571                 | 0,1228 | 0,0104 | 0,0097 |
| 13-3-0-0 | 0,8008                 | 0,1802 | 0,0100 | 0,0090 |
| 12-4-0-0 | 0,7422                 | 0,2385 | 0,0095 | 0,0098 |
| 11-5-0-0 | 0,6825                 | 0,2958 | 0,0123 | 0,0093 |
| 10-6-0-0 | 0,6200                 | 0,3566 | 0,0111 | 0,0123 |
| 9-7-0-0  | 0,5582                 | 0,4181 | 0,0128 | 0,0109 |
| 8-8-0-0  | 0,4891                 | 0,4846 | 0,0130 | 0,0133 |
| 8-4-4-0  | 0,5045                 | 0,2437 | 0,2406 | 0,0113 |
| 7-4-4-1  | 0,4397                 | 0,2461 | 0,2436 | 0,0705 |
| 6-4-4-2  | 0,3797                 | 0,2471 | 0,2445 | 0,1287 |
| 5-4-4-3  | 0,3175                 | 0,2439 | 0,2473 | 0,1913 |
| 4-4-4-4  | 0,2462                 | 0,2494 | 0,2549 | 0,2495 |

# Detecção de Comunidades Sobrepostas em Redes Complexas com Competição de Partículas

- Classificação da Rede do Clube de Caratê de Zachary. As cores representam o índice de sobreposição de cada nó, detectados pelo método proposto.






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

- Competição e cooperação entre partículas na rede
  - Cooperação entre partículas do mesmo time (rótulo / classe)
  - Competição entre os times pela posse dos nós da rede
- Cada time de partícula tenta:
  - Dominar a maior quantidade de nós possível de maneira cooperativa
  - Evitar a invasão de partículas de outros times em seu território

Breve, F. A., Zhao, L., Quiles, M. G., Pedrycz, W., & Liu, J. (2009e). **Particle competition and cooperation in networks for semi-supervised learning**. Artigo com versão revisada submetida para *IEEE Transactions on Knowledge and Data Engineering*.

# Configuração Inicial

- 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
- Níveis de domínio são ajustados da seguinte maneira:
  - Nós rotulados tem níveis de domínio fixos e ajustados para seus respectivos times
  - Nós não rotulados tem níveis de domínio variáveis e ajustados com valores iguais para todos os times



Ex: [ 1 0 0 0 ]

(4 classes/times, nó rotulado com classe A)





Ex: [ 0.25 0.25 0.25 0.25 ]

(4 classes/times, nós não rotulados)

$$v_i^{\omega_\ell}(0) = \begin{cases} 1 & \text{se } y_i = \ell \\ 0 & \text{se } y_i \neq \ell \text{ and } y_i \in L \\ \frac{1}{c} & \text{se } y_i = \emptyset \end{cases}$$

# Dinâmica de Nós

- Quando uma partícula seleciona um nó para visitar
  - Ela diminui o nível de domínio de outros times
  - Ela aumenta o nível de domínio de seu próprio time





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

# Dinâmica de Partículas

- Uma partícula se torna
  - Mais forte quando escolhe um nó dominado por seu time
  - Mais fraca quando escolhe um nó dominado por outro time

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



# Caminhada Aleatório-Gulosa

- Caminhada Aleatória

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

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

- Caminhada Gulosa

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


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

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



# 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




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

---

**Algoritmo 4.2:** Aprendizado semi-supervisionado com cooperação e competição entre partículas


---


- 1 Construa uma matriz de adjacências  $W$  usando a Equação (4.14) ou a Equação (4.15) ;
  - 2 Ajuste os níveis de domínio dos nós usando a Equação (4.17) ;
  - 3 Ajuste as posições iniciais das partículas de acordo com seus respectivos nós-casa usando a Equação (4.18) ;
  - 4 Ajuste a força das partículas e tabelas de distância usando a Equação (4.19) ;
  - 5 **repita**
    - 6     **para** cada partícula **faça**
      - 7         Selecione entre a regra aleatória ou gulosa com as probabilidades definidas por  $p_{\text{grd}}$  ;
      - 8         Selecione o nó alvo usando a Equação (4.23) ou a Equação (4.24) para movimento aleatório ou guloso respectivamente ;
      - 9         Atualize os níveis de domínio do nó alvo usando a Equação (4.20) ;
      - 10        Atualize a força da partícula usando a Equação (4.21) ;
      - 11        Atualize a tabela de distância das partículas usando a Equação (4.22) ;
  - 12 **até** que o critério de parada seja satisfeito;
  - 13 Rotule cada item de dado não rotulado pelo time com maior nível de domínio:  $y_i = \arg \max_{\ell} v_i^{\omega_{\ell}}(\infty)$ ;
-



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


$$\begin{aligned}l &= 50 \\ \langle k \rangle &= 25 \\ z_{\text{out}} &= 5 \\ z_{\text{out}} / \langle k \rangle &= 0,2\end{aligned}$$







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

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







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  
dados artificial com 1.200  
amostras igualmente  
divididas em três classes  
com distribuição  
Gaussiana.



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

- Comparação de Desempenho
  - Erros de teste (%) com 10 pontos de dados rotulados

|                        | <b>g241c</b> | <b>g241d</b> | <b>Digit1</b> | <b>USPS</b> | <b>COIL</b> | <b>BCI</b> | <b>Text</b> |
|------------------------|--------------|--------------|---------------|-------------|-------------|------------|-------------|
| <b>1-NN</b>            | 47,88        | 46,72        | 13,65         | 16,66       | 63,36       | 49,00      | 38,12       |
| <b>SVM</b>             | 47,32        | 46,66        | 30,60         | 20,03       | 68,36       | 49,85      | 45,37       |
| <b>MVU + 1-NN</b>      | 47,15        | 45,56        | 14,42         | 23,34       | 62,62       | 47,95      | 45,32       |
| <b>LEM + 1-NN</b>      | 44,05        | 43,22        | 23,47         | 19,82       | 65,91       | 48,74      | 39,44       |
| <b>QC + CMN</b>        | 39,96        | 46,55        | 9,80          | 13,61       | 59,63       | 50,36      | 40,79       |
| <b>Discrete Reg.</b>   | 49,59        | 49,05        | 12,64         | 16,07       | 63,38       | 49,51      | 40,37       |
| <b>TSVM</b>            | 24,71        | 50,08        | 17,77         | 25,20       | 67,50       | 49,15      | 31,21       |
| <b>SGT</b>             | 22,76        | 18,64        | 8,92          | 25,36       | -           | 49,59      | 29,02       |
| <b>Cluster-Kernel</b>  | 48,28        | 42,05        | 18,73         | 19,41       | 67,32       | 48,31      | 42,72       |
| <b>Data-Dep. Reg.</b>  | 41,25        | 45,89        | 12,49         | 17,96       | 63,65       | 50,21      | -           |
| <b>LDS</b>             | 28,85        | 50,63        | 15,63         | 17,57       | 61,90       | 49,27      | 27,15       |
| <b>Laplacian RLS</b>   | 43,95        | 45,68        | 5,44          | 18,99       | 54,54       | 48,97      | 33,68       |
| <b>CHM (normed)</b>    | 39,03        | 43,01        | 14,86         | 20,53       | -           | 46,90      | -           |
| <b>Método Proposto</b> | 43,14        | 43,94        | 11,75         | 17,75       | 58,65       | 47,67      | 34,53       |

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



- Comparação de Desempenho
  - Erros de teste (%) com 100 pontos de dados rotulados

|                        | <b>g241c</b> | <b>g241d</b> | <b>Digit1</b> | <b>USPS</b> | <b>COIL</b> | <b>BCI</b> | <b>Text</b> |
|------------------------|--------------|--------------|---------------|-------------|-------------|------------|-------------|
| <b>1-NN</b>            | 43,93        | 42,45        | 3,89          | 5,81        | 17,35       | 48,67      | 30,11       |
| <b>SVM</b>             | 23,11        | 24,64        | 5,53          | 9,75        | 22,93       | 34,31      | 26,45       |
| <b>MVU + 1-NN</b>      | 43,01        | 38,20        | 2,83          | 6,50        | 28,71       | 47,89      | 32,83       |
| <b>LEM + 1-NN</b>      | 40,28        | 37,49        | 6,12          | 7,64        | 23,27       | 44,83      | 30,77       |
| <b>QC + CMN</b>        | 22,05        | 28,20        | 3,15          | 6,36        | 10,03       | 46,22      | 25,71       |
| <b>Discrete Reg.</b>   | 43,65        | 41,65        | 2,77          | 4,68        | 9,61        | 47,67      | 24,00       |
| <b>TSVM</b>            | 18,46        | 22,42        | 6,15          | 9,77        | 25,80       | 33,25      | 24,52       |
| <b>SGT</b>             | 17,41        | 9,11         | 2,61          | 6,80        | -           | 45,03      | 23,09       |
| <b>Cluster-Kernel</b>  | 13,49        | 4,95         | 3,79          | 9,68        | 21,99       | 35,17      | 24,38       |
| <b>Data-Dep. Reg.</b>  | 20,31        | 32,82        | 2,44          | 5,10        | 11,46       | 47,47      | -           |
| <b>LDS</b>             | 18,04        | 23,74        | 3,46          | 4,96        | 13,72       | 43,97      | 23,15       |
| <b>Laplacian RLS</b>   | 24,36        | 26,46        | 2,92          | 4,68        | 11,92       | 31,36      | 23,57       |
| <b>CHM (normed)</b>    | 24,82        | 25,67        | 3,79          | 7,65        | -           | 36,03      | -           |
| <b>Modelo Proposto</b> | 24,20        | 23,93        | 2,65          | 4,99        | 16,48       | 44,38      | 25,03       |




# 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

---

Principais Contribuições

Trabalhos Futuros

# Conclusões

- A combinação de dinâmica e estrutura se mostrou uma abordagem bastante adequada para tratamento dos problemas computacionais abordados nessa tese. Conseqüentemente, 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 competição 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, mostrando ser uma abordagem de aprendizado bastante promissora, e abrindo 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.

# Conclusões

- Trabalhos futuros em atenção visual
  - Criar um mapa de saliência completo, utilizando outros atributos, como cores, saturação, orientação, dentre outros;
  - Verificar a possibilidade de incluir algum mecanismo de viés para simular algum conhecimento a priori sobre a imagem de entrada, como o efeito de memória de algum objeto específico;
- Trabalhos futuros em movimentação de partículas
  - Estudar outras formas de compor a rede a partir dos dados de entrada, incluindo outras medidas de distância e informações sobre a base de dados disponíveis a priori;
  - Estudar novas medidas que possam ser extraídas das informações temporais do algoritmo, da mesma forma que foi feito com a medida de sobreposição de um elemento;

# Publicações

- Artigos publicados ou submetidos para periódicos internacionais que tiveram a participação do doutorando como autor ou co-autor:
  1. BREVE, Fabricio Aparecido; ZHAO, Liang; QUILES, Marcos Gonçalves; PEDRYCZ, Witold; LIU, Jimming. **Particle competition and cooperation in networks for semi-supervised learning**. Artigo com versão revisada submetida para *IEEE Transactions on Knowledge and Data Engineering*.
  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.
  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.
  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:
  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.
  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.
  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:
  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.
  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.
  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.
  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.



# Aprendizado de Máquina em Redes Complexas

**Fabrizio Aparecido Breve**  
**Orientador: Prof. Dr. Zhao Liang**