

Redes Neurais: A Terceira Geração

Sumário

- Gerações de Redes Neurais
 - Modelos de Neurônios
- Sistemas Dinâmicos
 - Tipos de Dinâmica
- Correlação Oscilatória
- Sincronização em Sistemas Dinâmicos
 - Sincronização Completa
 - Sincronização por Fase
- Alguns modelos baseados em correlação oscilatória

Gerações de Redes Neurais

- Primeira Geração
 - Neurônios com saída binária
 - Exemplo: neurônio MCP (McCulloch & Pitts, 1943)
- Segunda Geração
 - Neurônios com saídas mapeadas por funções contínuas
 - Funções sigmóide, etc.
 - Capazes de computar funções com entradas e saídas analógicas
 - Do ponto de vista biológico podem ser interpretadas como nível de ativação dos neurônios
 - Suportam algoritmos de aprendizado baseados em gradiente
 - Exemplo: Backpropagation

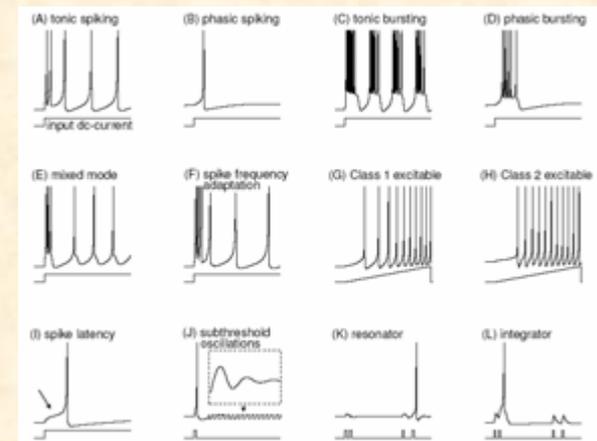
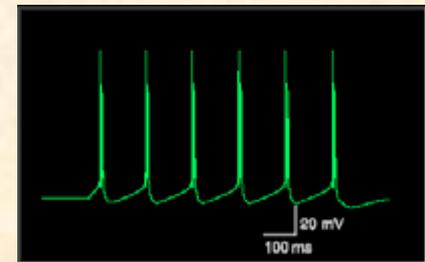
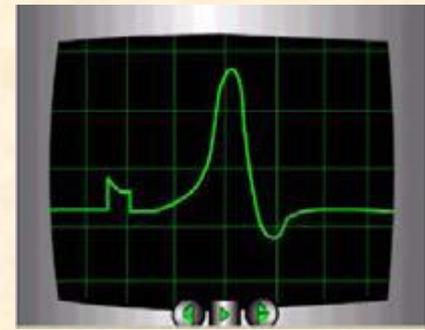
Gerações de Redes Neurais

- Terceira Geração

- Neurônios mais próximos do neurônio biológico
- Conhecidas como Redes Neurais Pulsadas (*Spiking Neural Networks*)
- Utilizam pulsos como saída
- Representação temporal através de pulsos gerados no tempo
- Modelos de redes diferem no tipo de neurônio com o qual são compostos.

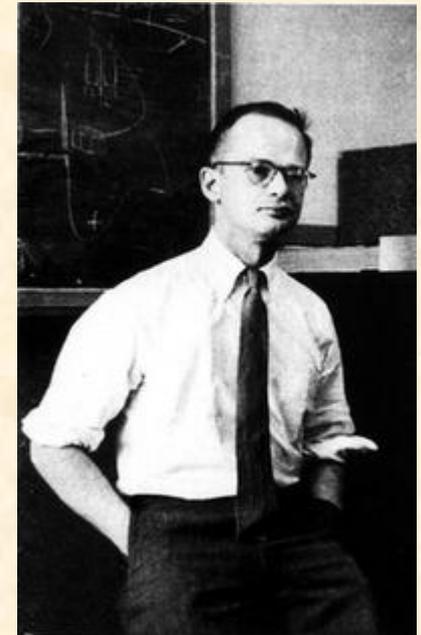
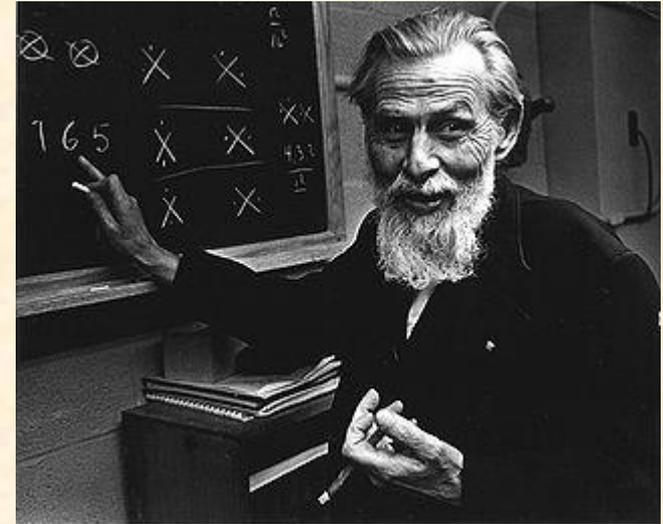
- Exemplos:

- Integra e Dispara (*Integrate-and-Fire*)
 - Bastante simples
- Hodgkin-Huxley
 - Descrevem com alto grau de fidelidade os aspectos biofísicos do neurônio biológico



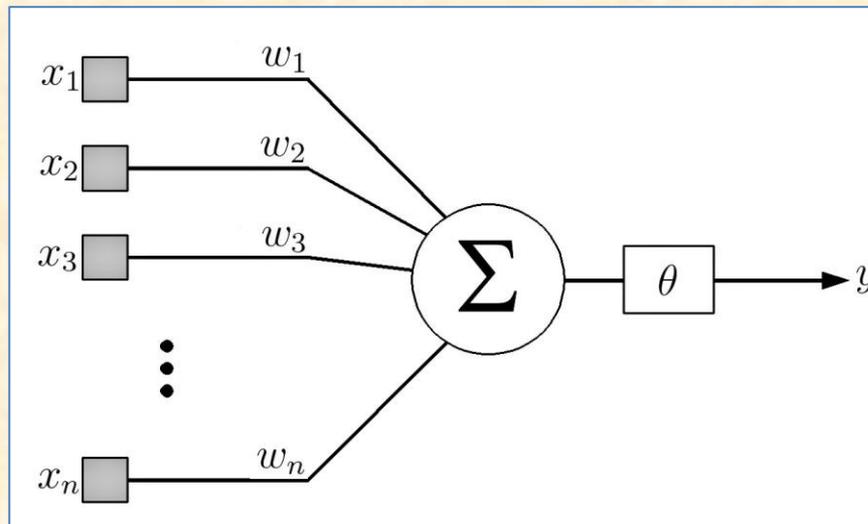
O Neurônio MCP

- Em 1943, considerando o que se conhecia até o momento (década de 40) os pesquisadores Warren McCulloch e Walter Pitts propuseram o primeiro modelo matemático para um neurônio artificial
 - Pode ser visto como uma simplificação do que já havia sido descoberto a respeito do neurônio biológico

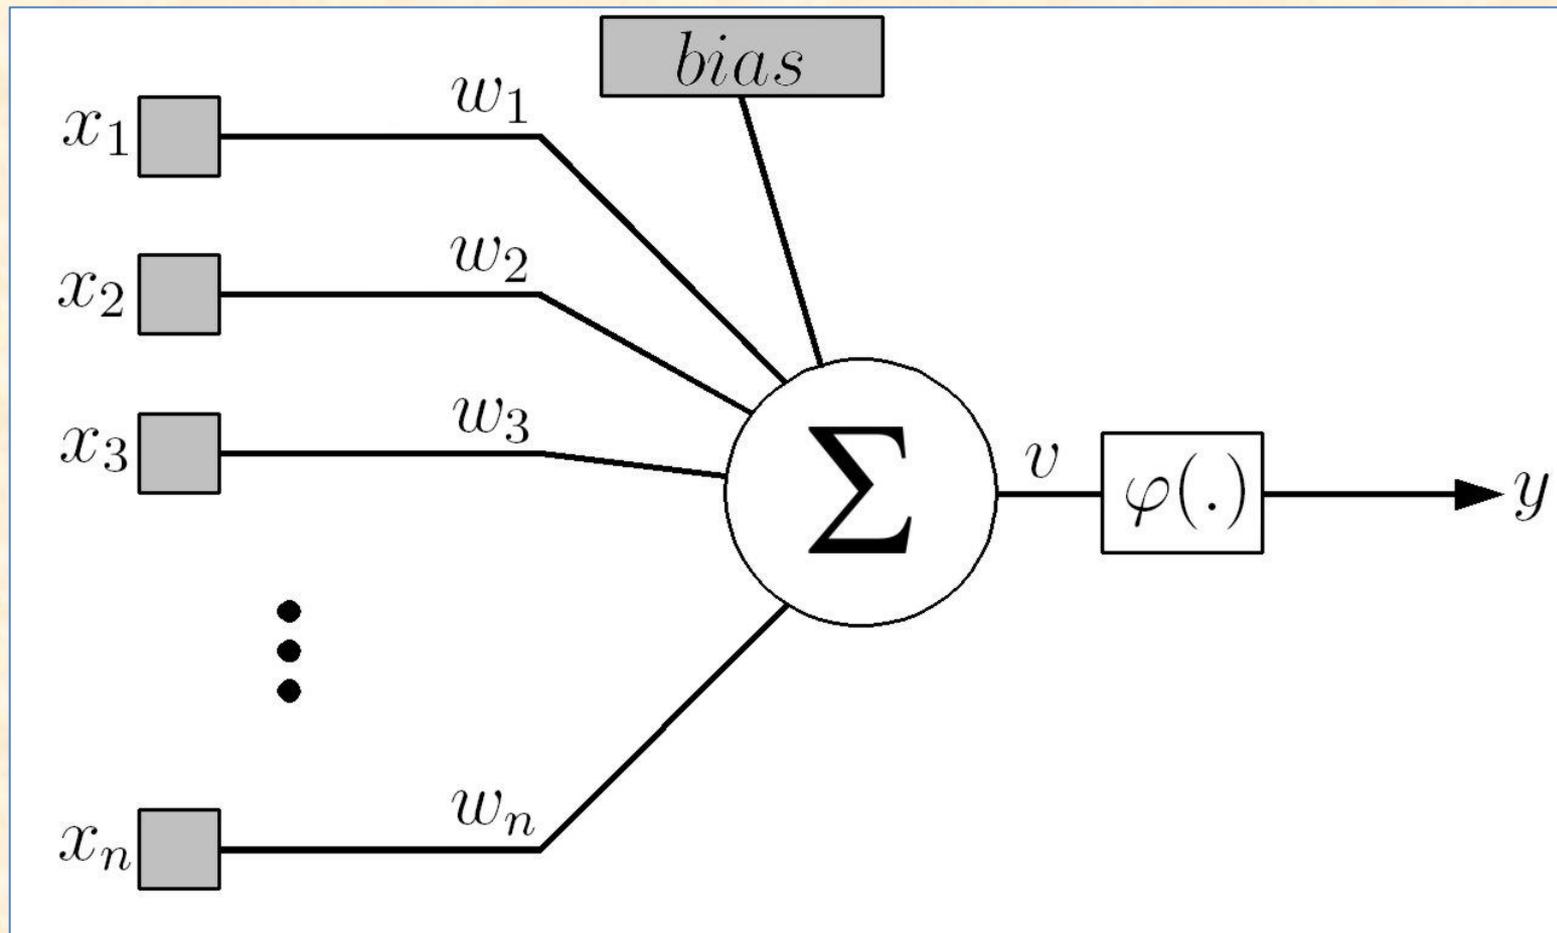


O Neurônio MCP

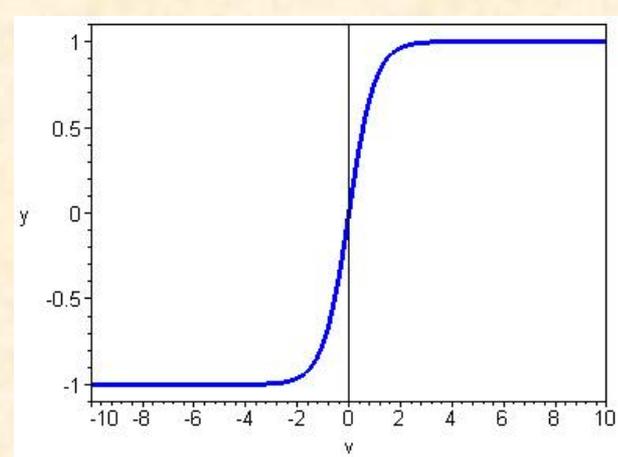
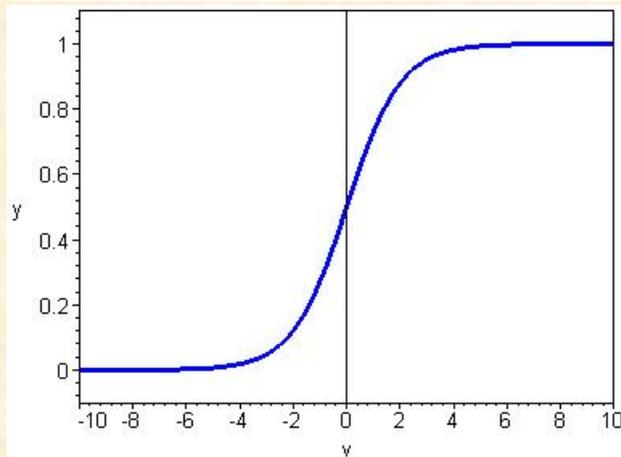
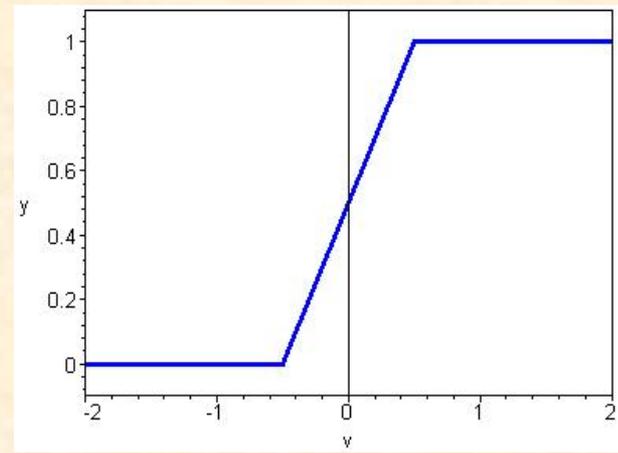
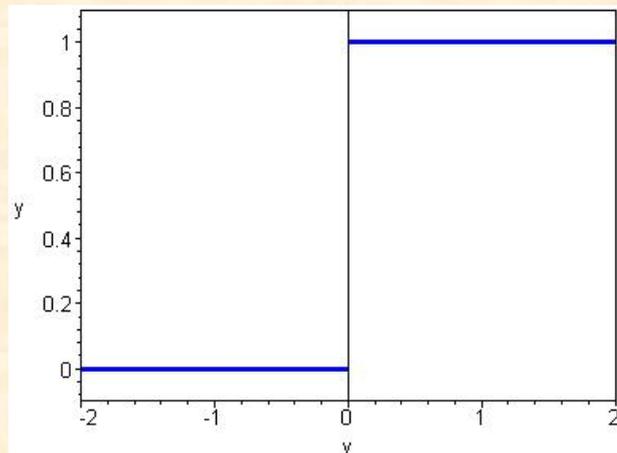
- O Nó MCP é composto por:
 - Diversas entradas (dendritos)
 - Ponderadas por pesos (comportamento das sinapses)
 - Uma saída (axônio) que representa quando o neurônio está ativo ou não
 - Saída binária
 - Está disparando potenciais de ação ou está em repouso



MCP com função de ativação

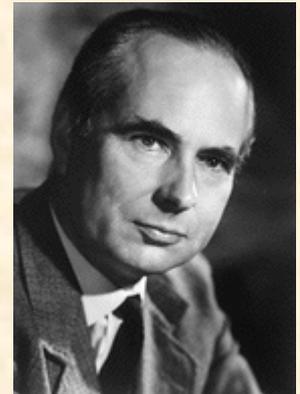
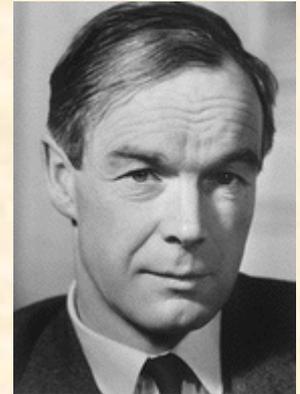


Funções de Ativação



O Modelo Hodgkin-Huxley

- Descrito pelos pesquisadores Alan Lloyd Hodgkin e Andrew Huxley em 1952
 - Em 1963, receberam o prêmio Nobel em Fisiologia ou Medicina por este trabalho
- Modelo matemático que descreve fielmente o comportamento eletrofisiológico do neurônio biológico
- Enfoque inicialmente fisiológico e não computacional
- Formado por um conjunto de equações diferenciais não-lineares



Hodgkin, A., and Huxley, A. (1952): A quantitative description of membrane current and its application to conduction and excitation in nerve. *J. Physiol.* **117**:500–544. [PMID 12991237](https://pubmed.ncbi.nlm.nih.gov/12991237/)

MCP X Hodgkin-Huxley

MCP

- Modelo digital
- Praticável computacionalmente
- Variações com saída contínua (Adaline)

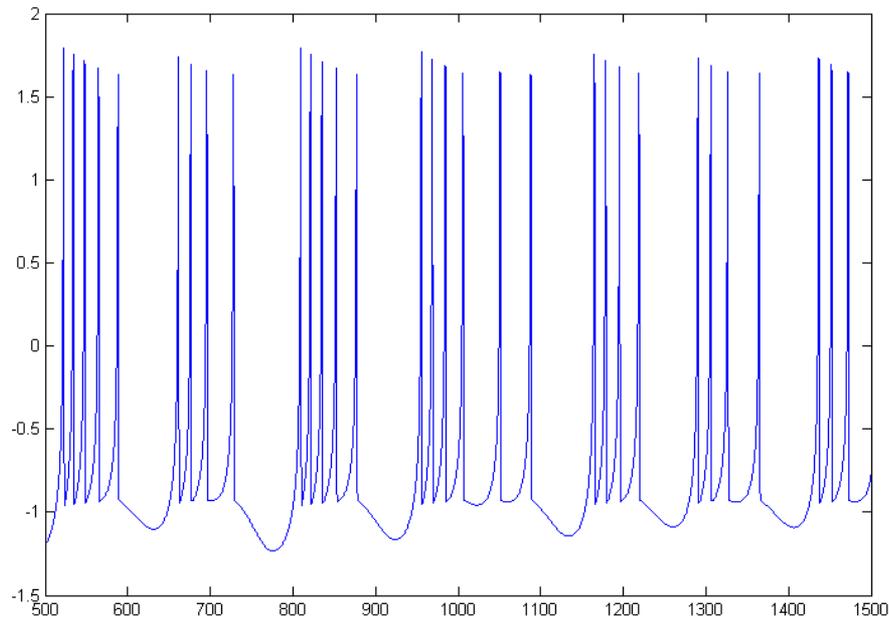
Modelo de Hodgkin-Huxley

- Descreve o comportamento dinâmico
- Impraticável computacionalmente
- Pulsos (Spikes)

Modelos derivados de Hodgkin-Huxley

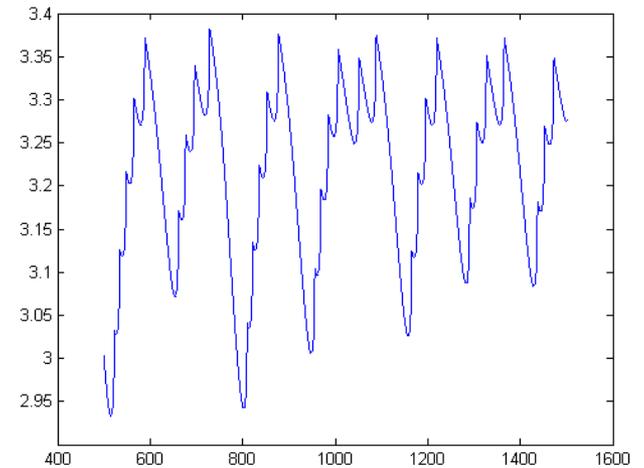
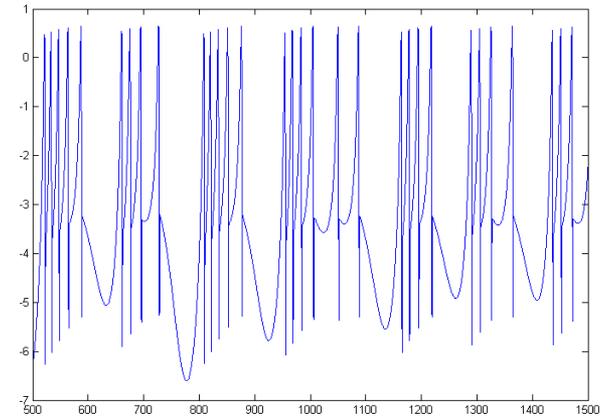
- FitzHugh-Nagumo
 - Modelo simplificado, mas com algumas novas características, introduzido por FitzHugh e Nagumo em 1961 e 1962
- Morris-Lecar
 - Modelo derivado de uma combinação de Hodgkin-Huxley e o FitzHugh-Nagumo, introduzido em 1981 por Morris e Lecar
- Hindmarsh-Rose
 - Derivado do modelo FitzHugh-Nagumo
 - Em 1984, J. L. Hindmarsh e R. M. Rose propuseram este modelo de atividade neural descrito por três equações diferenciais de primeira ordem acopladas
 - Permite uma grande variedade de comportamentos dinâmicos, incluindo o comportamento caótico

Hindmarsh-Rose

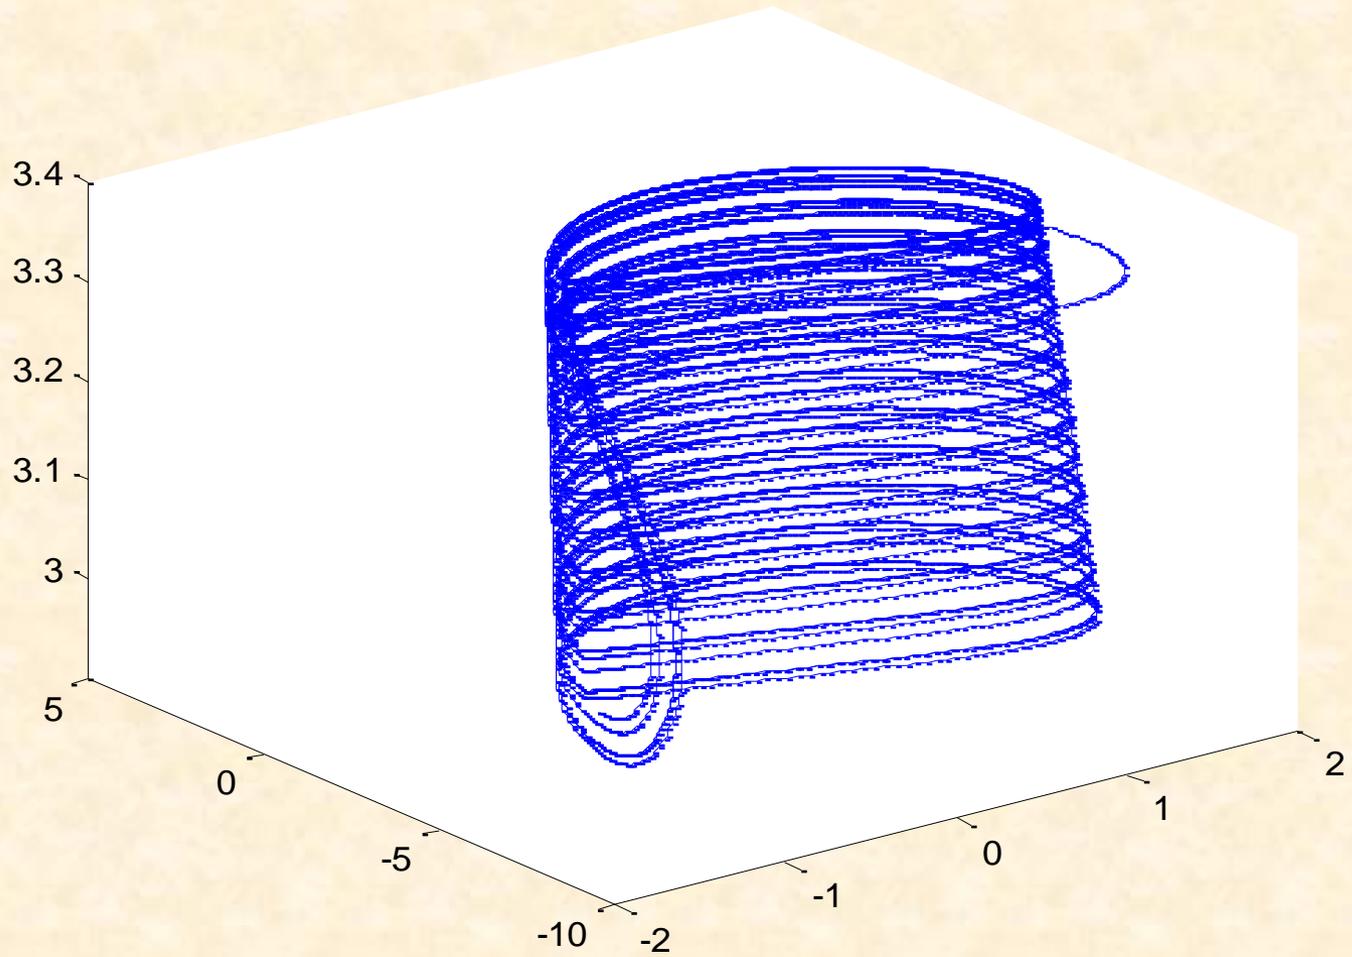


$$\begin{aligned}\frac{dx}{dt} &= y + \phi(x) - z + I, \\ \frac{dy}{dt} &= \psi(x) - y, \\ \frac{dz}{dt} &= r[s(x - x_R) - z],\end{aligned}$$

$$\begin{aligned}\phi(x) &= ax^2 - x^3, \\ \psi(x) &= 1 - bx^2.\end{aligned}$$



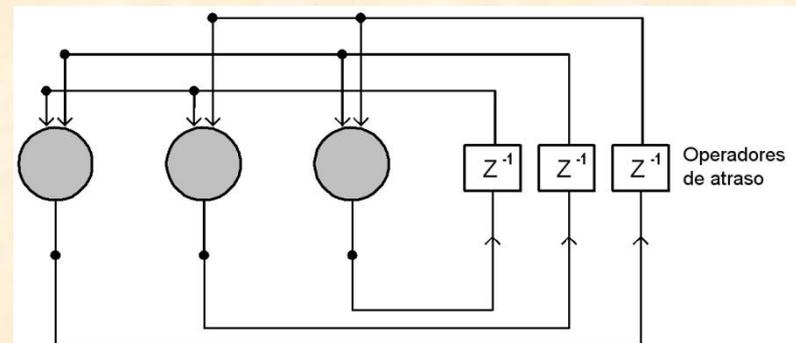
Hindmarsh-Rose



Sistemas Dinâmicos

Relembrando Arquitetura de Redes

- Redes Alimentadas Adiante
 - Não existe realimentação
- Redes Recorrentes
 - Pelo menos um laço de realimentação
 - Incorporam uma memória dinâmica
 - Estados de um neurônio em um instante t depende do estado dos demais neurônios em um momento anterior
 - Realimentação Local
 - Vizinhos mais próximos ou o próprio neurônio
 - Realimentação Global
 - Todos os neurônios da rede
 - Rede globalmente acoplada



Redes Neurais e Sistemas Dinâmicos

- Algumas descobertas de fenômenos biológicos nas últimas 3 décadas:
 - Sincronização de neurônios no córtex visual de mamíferos
 - Observação de comportamento caótico em neurônios e atividades cerebrais
- Para estudar e simular tais fenômenos podemos utilizar redes recorrentes
 - Estas redes podem ser vistas como sistemas dinâmicos não-lineares de alta dimensionalidade

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

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

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

Sistemas Dinâmicos

- Comportamento assintótico (quando $t \rightarrow \infty$)
 - Podem apresentar vários tipos de atratores
 - Ponto fixo
 - Ciclo-Limite
 - Quase-Periódico
 - Caótico
 - Exemplo:
 - Mapa Logístico
 - Discreto
 - Não-Linear
 - Unidimensional

$$x(t+1) = ax(t)(1-x(t))$$

onde x é variável de estado e a é parâmetro de bifurcação

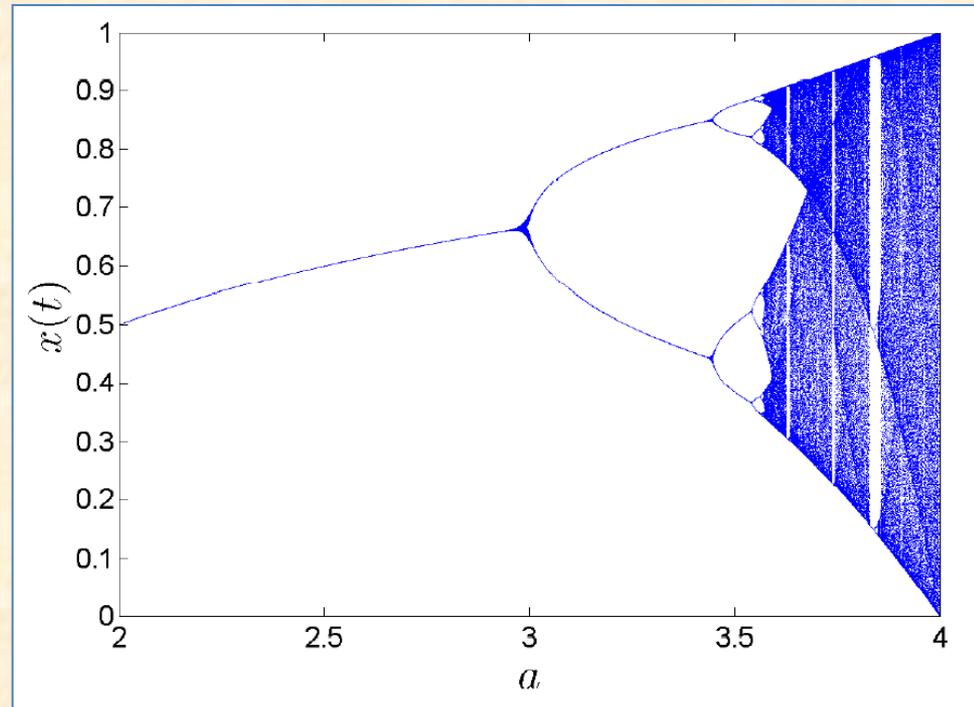
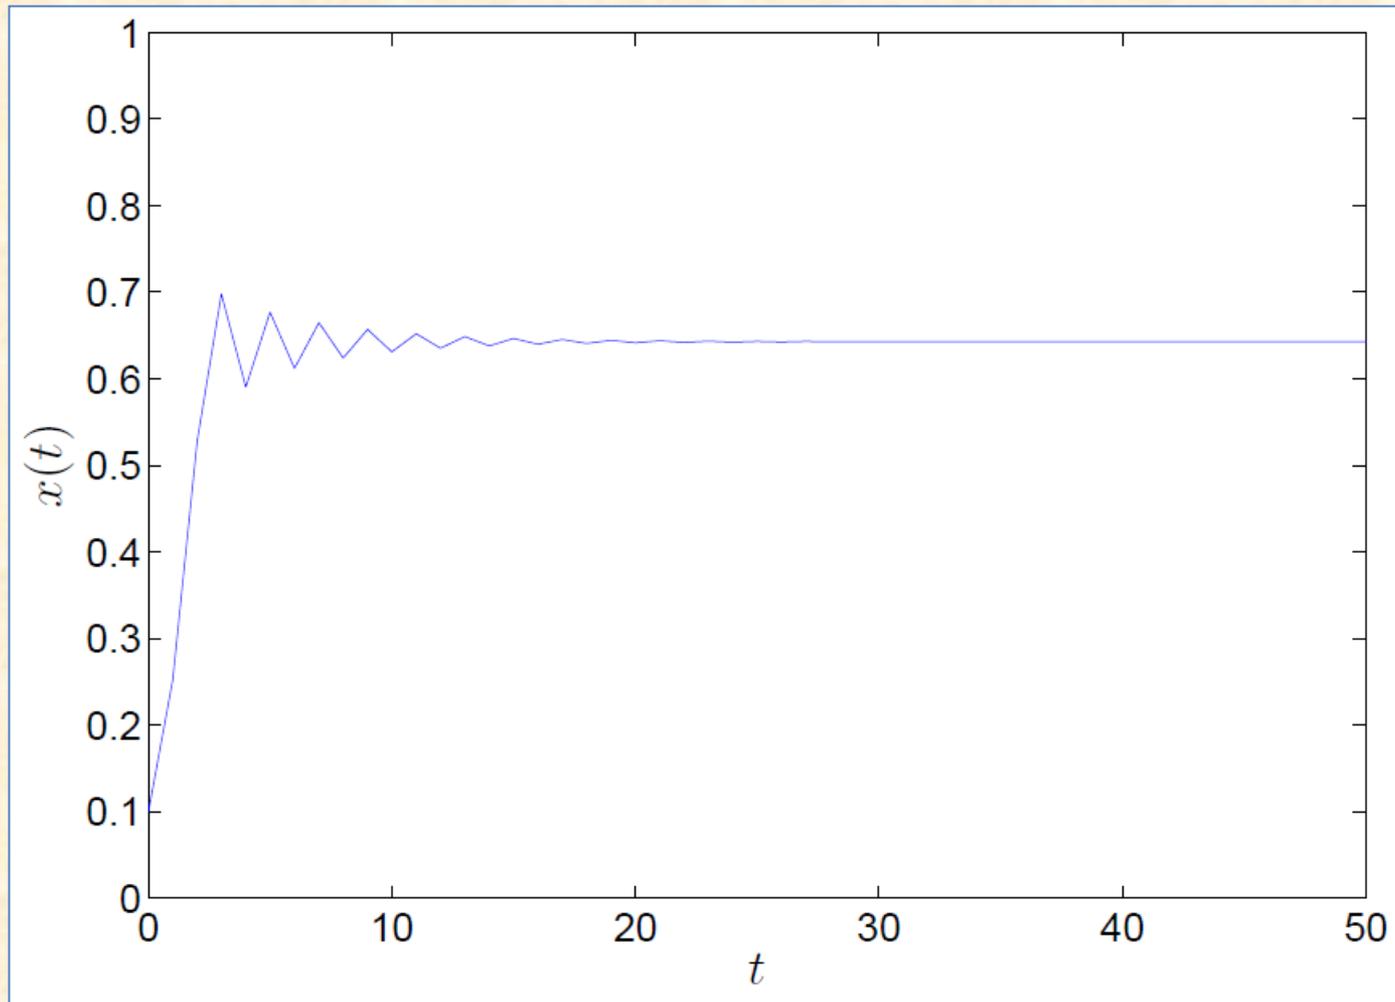


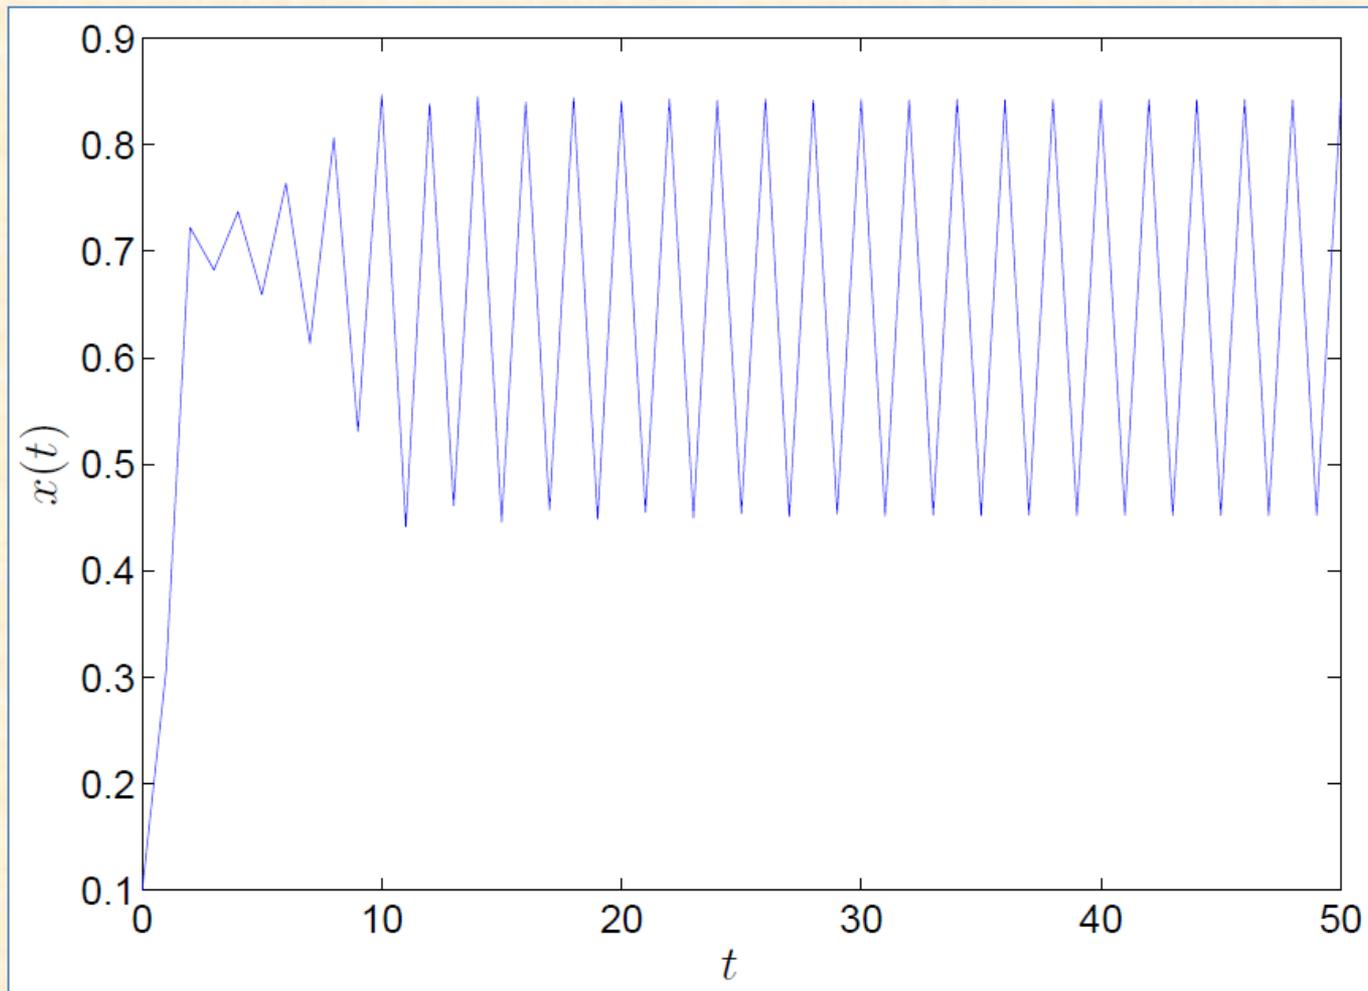
Diagrama de bifurcação para o mapa logístico

Dinâmica de Ponto Fixo



Dinâmica de Ponto Fixo no mapa logístico com coeficiente de bifurcação $a = 2,8$.

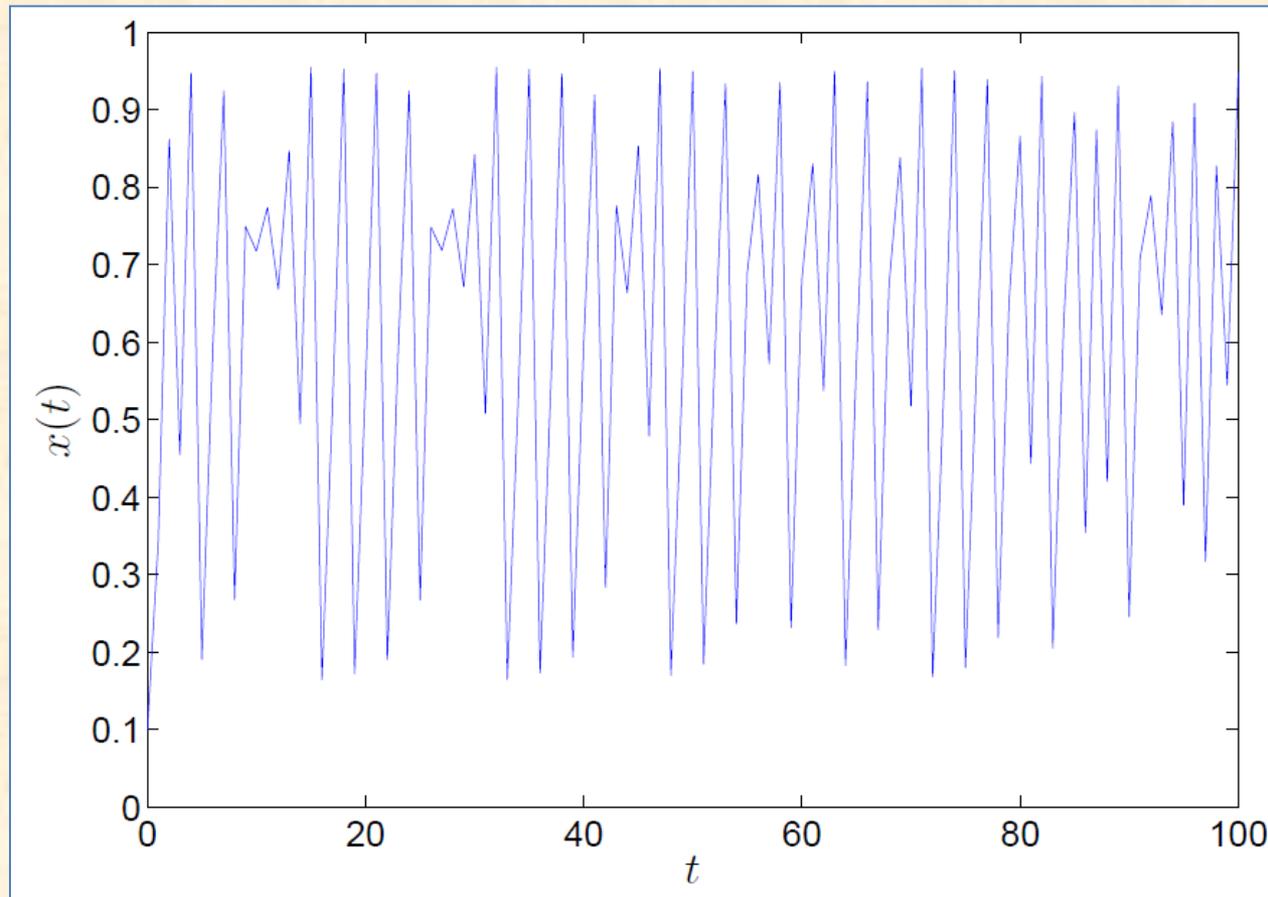
Dinâmica de Ciclo-Limite



Dinâmica de Ciclo Limite no mapa logístico com coeficiente de bifurcação $a = 3,4$ e 2 pontos periódicos

Dinâmica Quase-Periódica

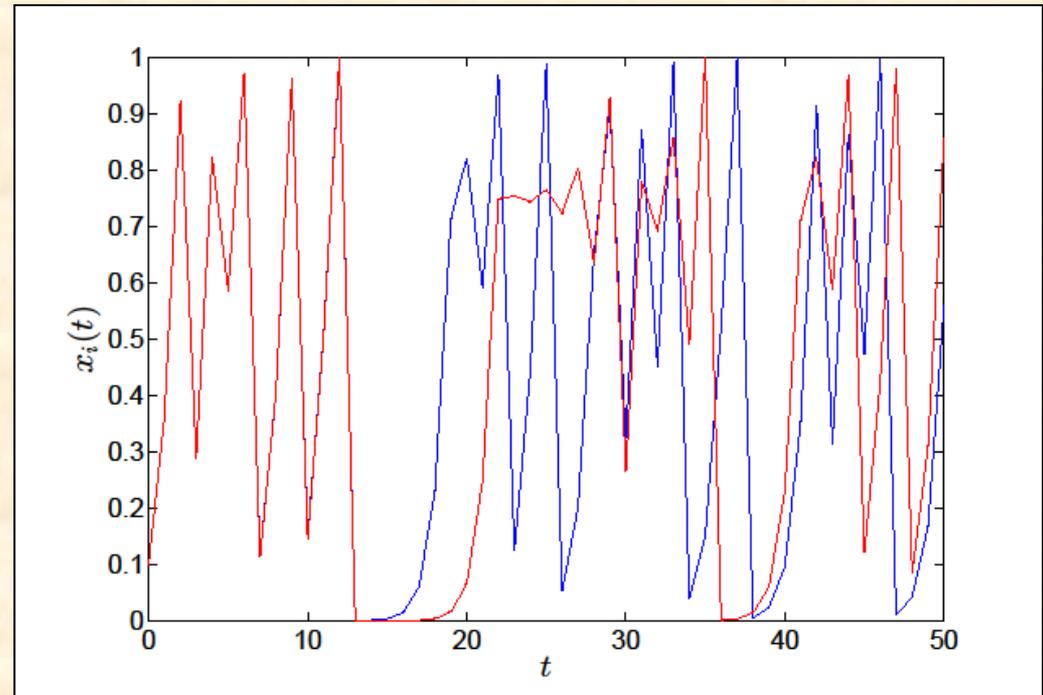
- Se assemelham a trajetórias periódicas, porém na dinâmica quase-periódica nenhum estado se repete para $t \rightarrow \infty$



Dinâmica Quase-Periódica no mapa logístico com coeficiente de bifurcação $a = 3,82$.

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 $x_2(0) = 0,100001$

Correlação Oscilatória

Correlação Oscilatória

- Experimentos fisiológicos têm evidenciado a existência de atividades rítmicas em conjuntos de neurônios de várias regiões do cérebro de mamíferos
 - Exemplo: Córtex visual do gato
- O pesquisador von der Malsburg apresentou em 1981 a Teoria da Correlação Temporal
 - Afirma que um objeto é representado pela correlação temporal dos disparos (potenciais de ação) de células neurais que representam diferentes características de um mesmo objeto

Eckhorn, R., Bauer, R., Jordan, W., Brosch, M., Kruse, W., Munk, M., & Reitboeck, H. J. (1988). **Coherent oscillation: A mechanism of feature linking in the visual cortex?** *Biological Cybernetics*, 60, 121–130.

von der Malsburg, C. (1981). **The Correlation Theory of Brain Function.** Internal Report 81-2, *Max Planck Institute for Biophysical Chemistry*.

Correlação Oscilatória

- Uma maneira de realizar a correlação temporal é através do uso de osciladores
 - Cada oscilador pode representar um conjunto de características (cor, orientação, movimentação, profundidade, etc.) de tal forma que cada segmento (objeto-cluster) é representado por um conjunto de osciladores com atividades síncronas (em fase) enquanto que segmentos distintos são representados por grupos de osciladores fora de sincronia
 - Esta forma de correlação temporal é chamada de *Correlação Oscilatória*

Terman, D. & Wang, D. L. (1995). **Global competition and local cooperation in a network of neural oscillators.** *Physica D*, 81(1-2), 148–176.

Wang, D. & Terman, D. (1997). **Image segmentation based on oscillatory correlation.** *Neural Computation*, 9(4), 805–836.

Correlação Oscilatória

- A correlação oscilatória também pode ser observada em outros tipos de elementos dinâmicos de rede
- Exemplo:
 - Em 2001, os pesquisadores Zhao e Macau propuseram uma rede de mapas caótico acoplados que utilizam as propriedades do caos e da sincronização caótica para obter o comportamento de sincronia e dessincronia

Zhao, L. & Macau, E. E. N. (2001). **A network of dynamically coupled chaotic maps for scene segmentation**. *IEEE Transactions on Neural Networks*, 12(6), 1375–1385.

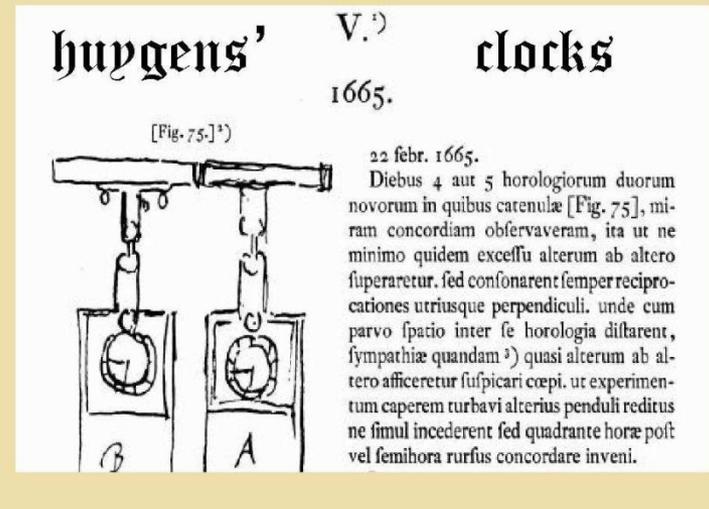
Correlação Oscilatória

- Modelos de correlação oscilatória vêm sendo desenvolvidos para as mais diversas tarefas:
 - Segmentação
 - Segmentação de Movimento
 - Clusterização de Pixels
 - Segregação de Sinais Sonoros
 - Percepção
 - Clusterização

Sincronização em Sistemas Dinâmicos

Sincronização em Sistemas Dinâmicos

- Característica básica de sistemas não-lineares.
- O pesquisador holandês Christiaan Huygens (1629-1695) foi o primeiro a observar e descrever este fenômeno em dois osciladores periódicos acoplados
 - Em dois relógios de pêndulo pendurados em um suporte comum, uma viga de madeira em uma casa, Huygens observou que os pêndulos oscilavam exatamente na mesma frequência e com uma diferença de fase de 180 graus.
 - Quando um dos pêndulos era perturbado, a sincronização se restabelecia em um período de meia hora e permanecia indefinidamente.



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 Completa

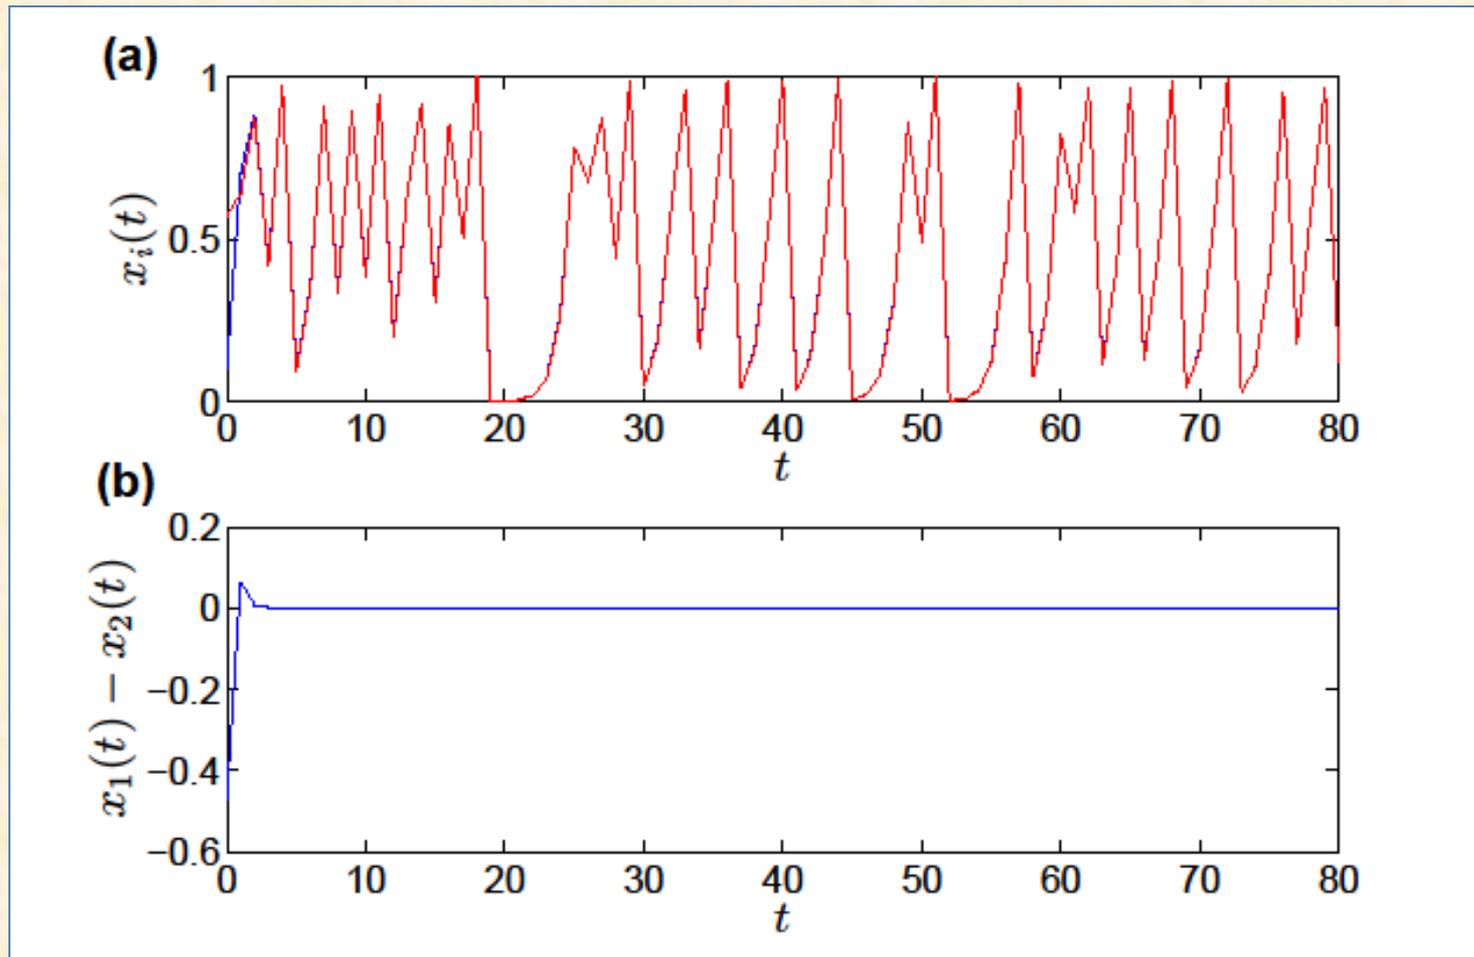
Sincronização Completa

- Se caracteriza pela coincidência das trajetórias de dois ou mais sistemas acoplados
- Se x e y são dois sistemas dinâmicos, dizemos que eles estão completamente sincronizados se $|x(t) - y(t)| \rightarrow 0$ conforme $t \rightarrow \infty$
- Exemplo: dois mapas logísticos acoplados

$$\begin{aligned}x_1(t) &= (1 - \varepsilon)f(x_1(t)) + \varepsilon f(x_2(t)), \\x_2(t) &= (1 - \varepsilon)f(x_2(t)) + \varepsilon f(x_1(t)),\end{aligned}$$

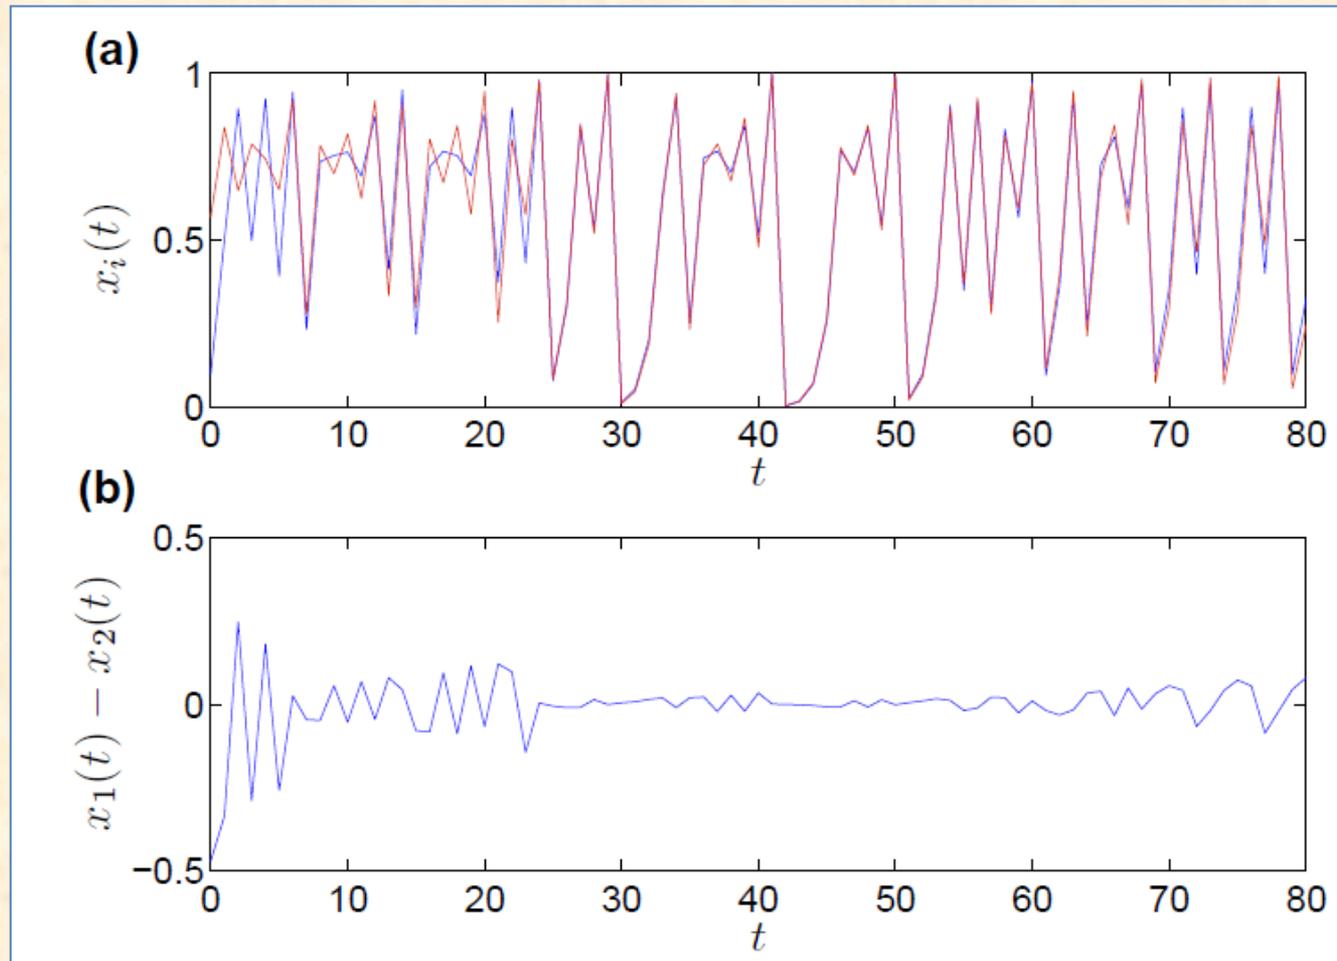
onde ε é chamado *força de acoplamento*

Sincronização Completa



Dois mapas logísticos acoplados com $\varepsilon = 0,45$ (a) Séries temporais dos dois osciladores juntos (b) Diferença entre os dois osciladores.

Sincronização Completa



Dois mapas logísticos acoplados com $\varepsilon = 0,23$ (a) Séries temporais dos dois osciladores juntos (b) Diferença entre os dois osciladores.

Sincronização Completa em Sistemas Contínuos

- Exemplo: oscilador Wilson-Cowan

$$\begin{aligned}\dot{x} &= -ax + G(cx + ey + I - \theta_x), \\ \dot{y} &= -by + G(dx + fy - \theta_y), \\ G(v) &= \frac{1}{1 + e^{-v/T}},\end{aligned}$$

a e b são parâmetros de decaimento (números positivos) de x e y respectivamente
 c e f são parâmetros auto-excitatórios;

e é a força de acoplamento da unidade inibitória y para a unidade excitatória x

θ é um valor negativo para garantir que a variável y haja como inibitória.

A força de acoplamento de x para y é dada por d .

x e y são limiares das unidades x e y respectivamente.

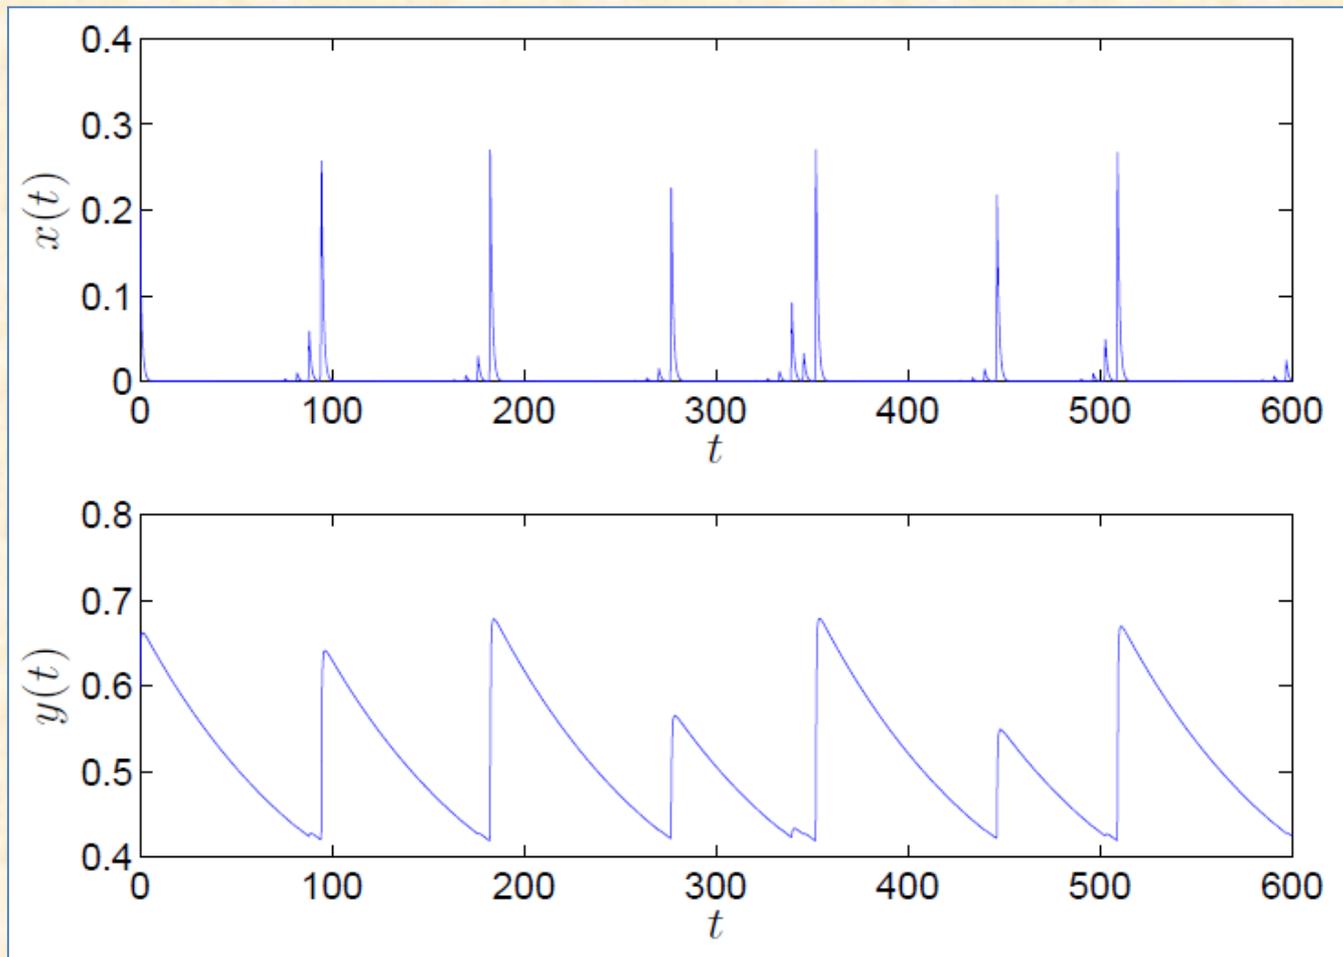
$G(\cdot) \in [0, 1]$ é uma função sigmoideal e T define a sua inclinação.

I é um estímulo externo. Se I é uma constante, não existe caos, pois será um fluxo bidimensional contínuo. Para obter um oscilador caótico, o estímulo externo precisa ser definido como uma função periódica:

$$I(t) = A \cos(t)$$

onde A é a amplitude da função dirigente.

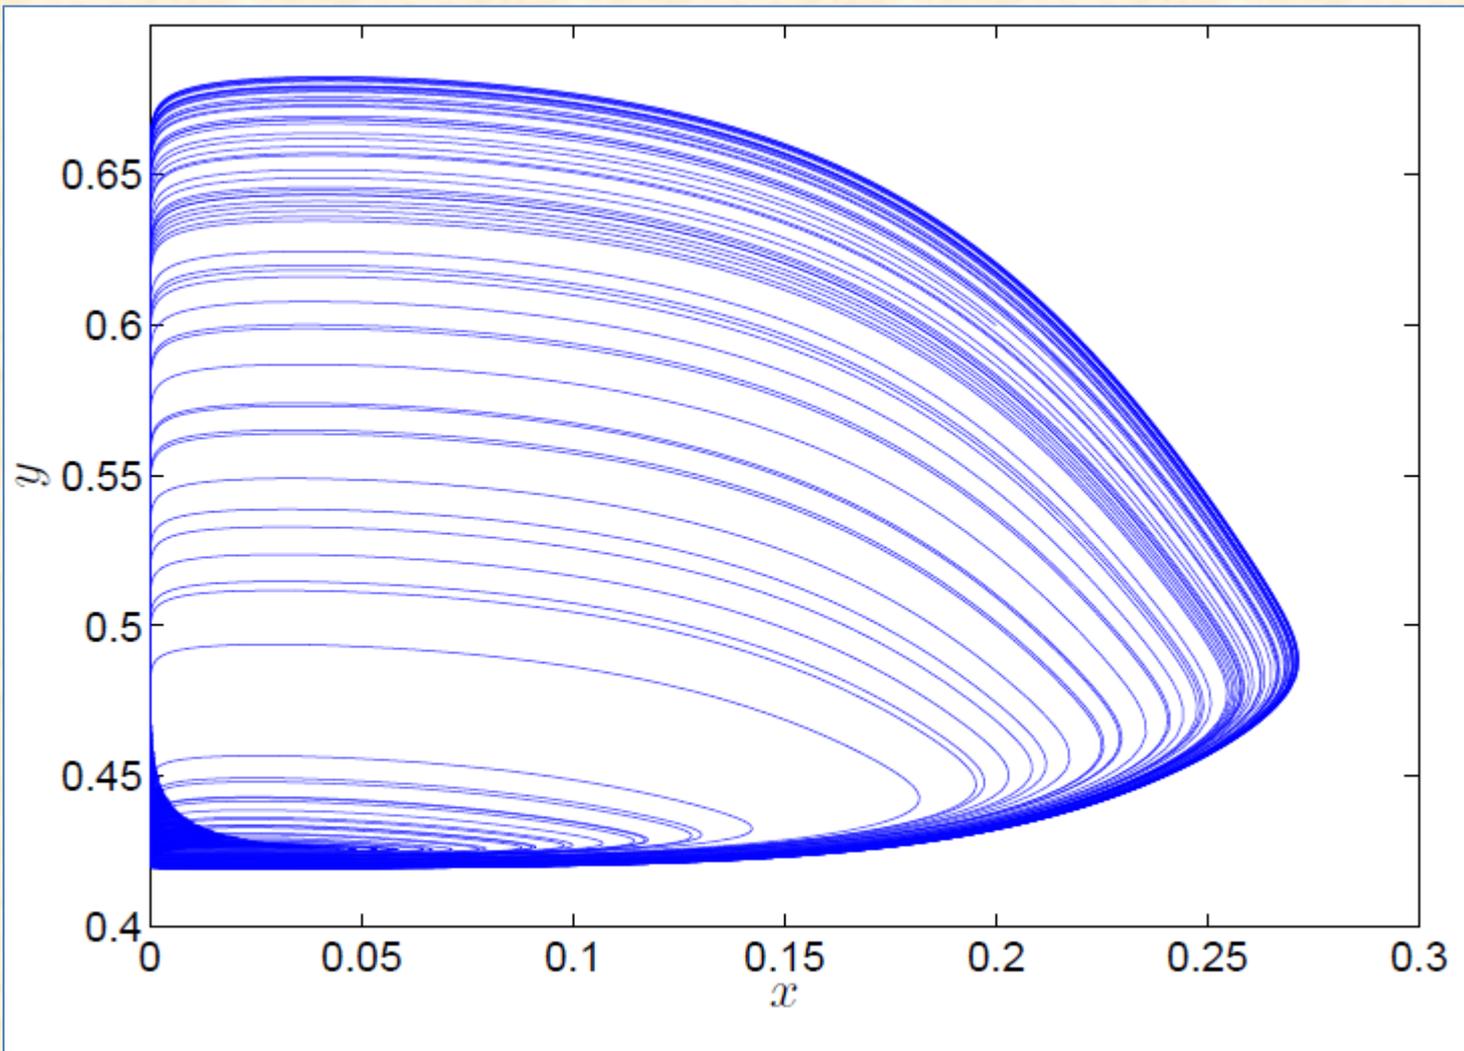
Osciladores Wilson-Cowan



$A = 1,2$
 $a = 1,0$
 $b = 0,001$
 $c = 1,0$
 $d = 0,6$
 $e = -2,5$
 $f = 0,0$
 $\theta_x = 0,2$
 $\theta_y = 0,15$
 $T = 0,025$

Série Temporal das unidades x e y de um Oscilador Wilson-Cowan.

Osciladores Wilson-Cowan



$A = 1,2$
 $a = 1,0$
 $b = 0,001$
 $c = 1,0$
 $d = 0,6$
 $e = -2,5$
 $f = 0,0$
 $\theta_x = 0,2$
 $\theta_y = 0,15$
 $T = 0,025$

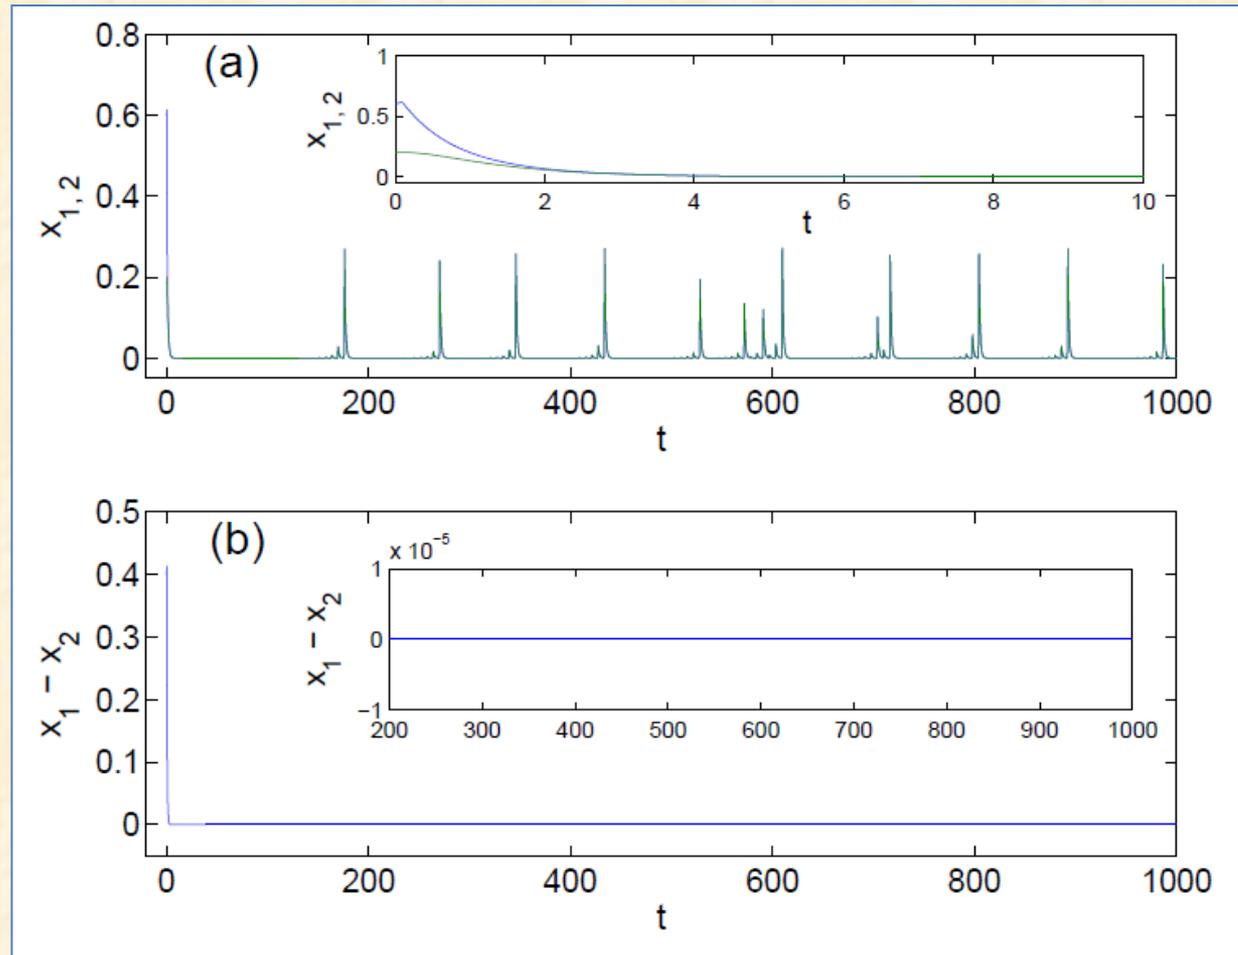
Trajétória de fase de um Oscilador Wilson-Cowan

Sincronização Completa entre Osciladores Wilson-Cowan

$$\begin{aligned} \dot{x}_1 &= ax_1 + G(cx_1 + ey_1 + I - \theta_x) + k(x_2 - x_1), \\ \dot{y}_1 &= -by_1 + G(dx_1 + fy_1 - \theta_y + k(y_2 - y_1)), \\ \dot{x}_2 &= ax_2 + G(cx_2 + ey_2 + I - \theta_x) + k(x_1 - x_2), \\ \dot{y}_2 &= -by_2 + G(dx_2 + fy_2 - \theta_y + k(y_1 - y_2)), \\ G(v) &= \frac{1}{1 + \exp[-v(v/T)]}, \\ I &= \cos(t), \end{aligned}$$

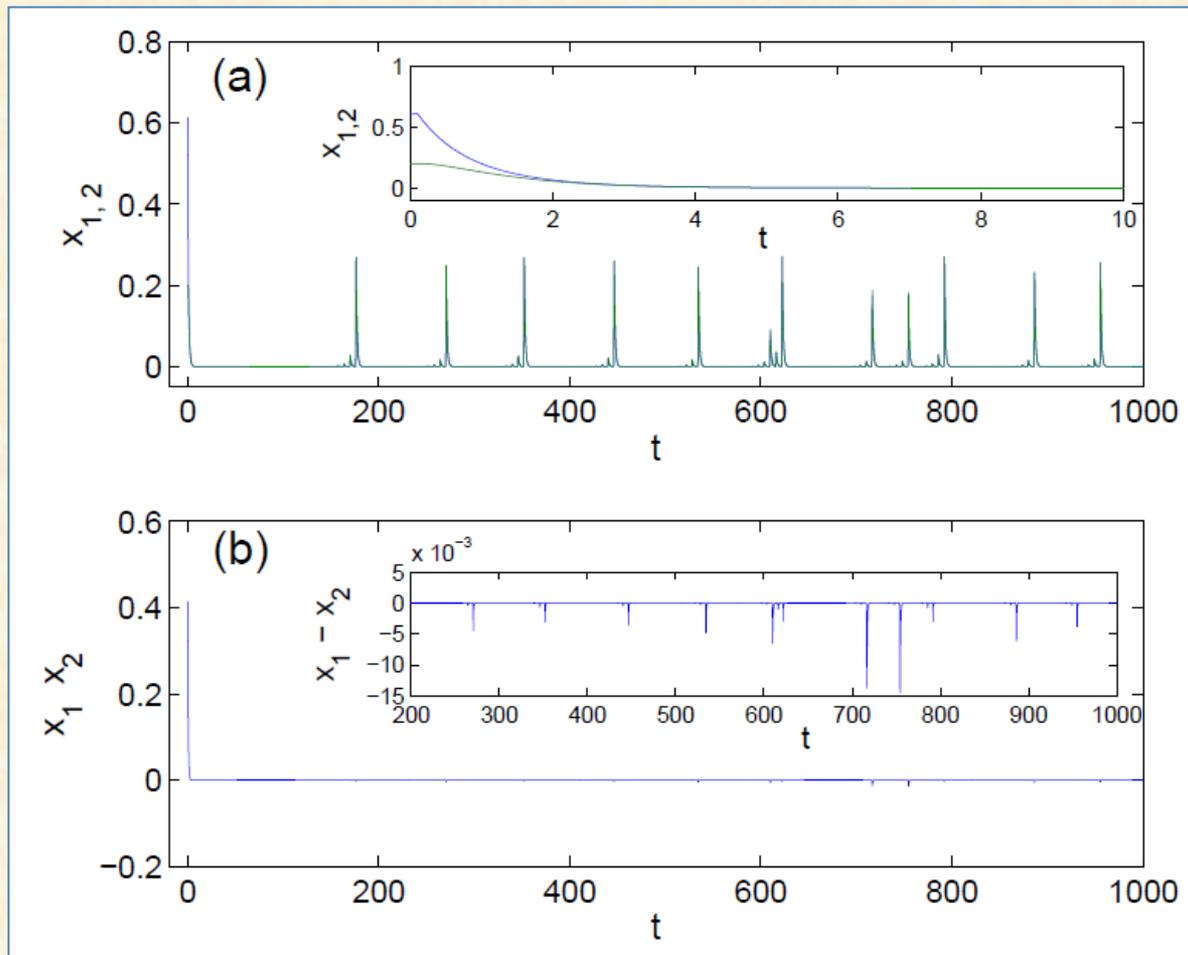
onde k é a força de acoplamento

Sincronização Completa entre Osciladores Wilson-Cowan



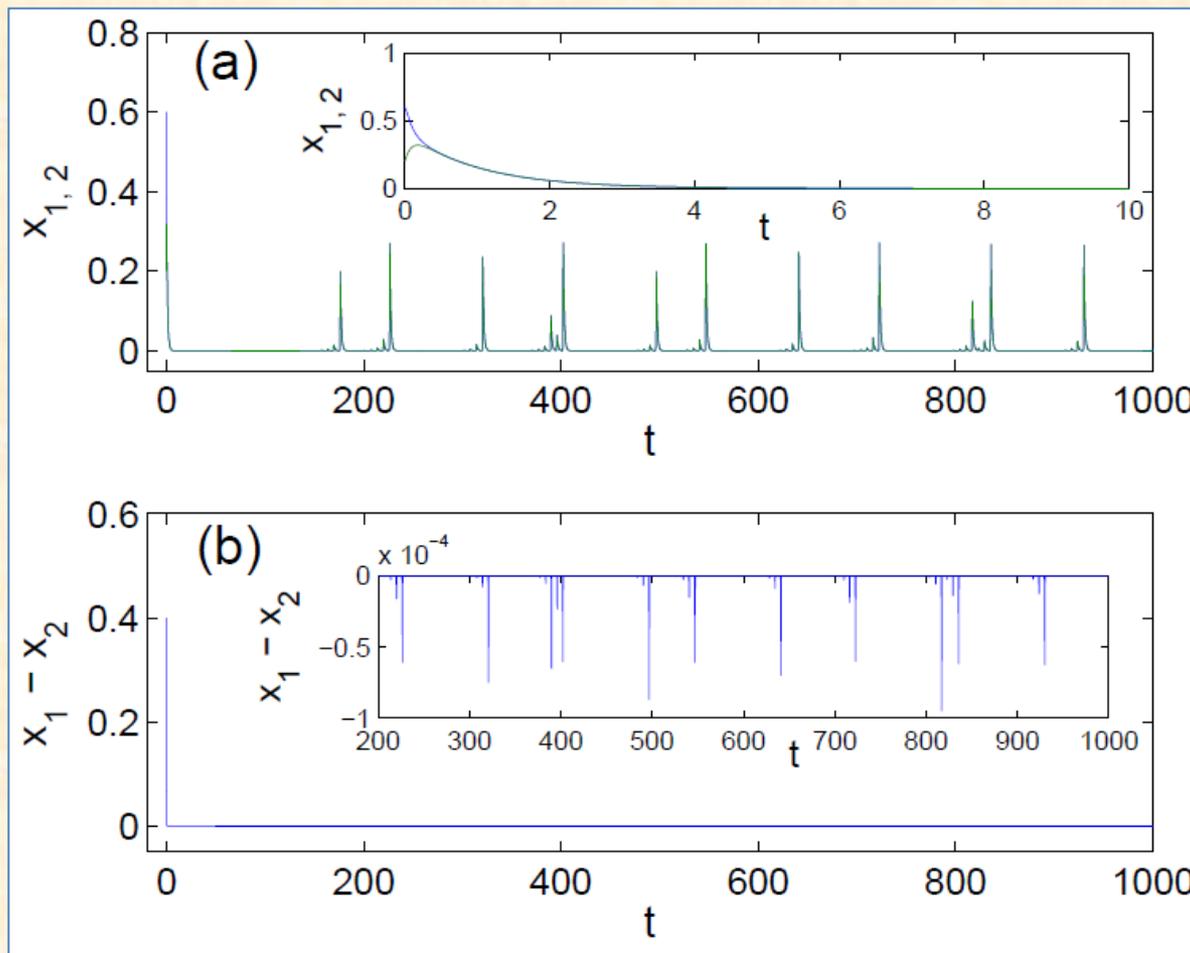
Dois osciladores Wilson-Cowan acoplados com $k = 0,5$ (a) Séries temporais da unidade x de dois osciladores juntos. O gráfico interno mostra uma ampliação das primeiras 10 unidades de tempo. (b) Diferença da variável x dos dois osciladores. O gráfico interno mostra essa diferença em uma escala mais fina.

Sincronização Completa entre Osciladores Wilson-Cowan



Dois osciladores Wilson-Cowan acoplados com $\theta_{x_1} = 0,2$ e $\theta_{x_2} = 0,201$ onde θ_{x_1} e θ_{x_2} são os parâmetros θ_x dos osciladores 1 e 2 respectivamente, $k = 0,5$ (a) Séries temporais da unidade x de dois osciladores juntos. O gráfico interno mostra uma ampliação das primeiras 10 unidades de tempo. (b) Diferença da variável x dos dois osciladores. O gráfico interno mostra essa diferença em uma escala mais fina.

Sincronização Completa entre Osciladores Wilson-Cowan



Dois osciladores Wilson-Cowan acoplados com $\theta_{x_1} = 0,2$ e $\theta_{x_2} = 0,201$ onde θ_{x_1} e θ_{x_2} são os parâmetros θ_x dos osciladores 1 e 2 respectivamente, $k = 5,0$ (a) Séries temporais da unidade x de dois osciladores juntos. O gráfico interno mostra uma ampliação das primeiras 10 unidades de tempo. (b) Diferença da variável x dos dois osciladores. O gráfico interno mostra essa diferença em uma escala mais fina.

Sincronização por Fase

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 permanecem não relacionadas
- Sejam dois osciladores caóticos com fases definidas por ϕ_1 e ϕ_2 . Dizemos que ambos estão sincronizados se a diferença entre suas respectivas fases $\phi_1 - \phi_2$ é limitada, por exemplo: $\phi_1 - \phi_2 < M$, conforme $t \rightarrow \infty$

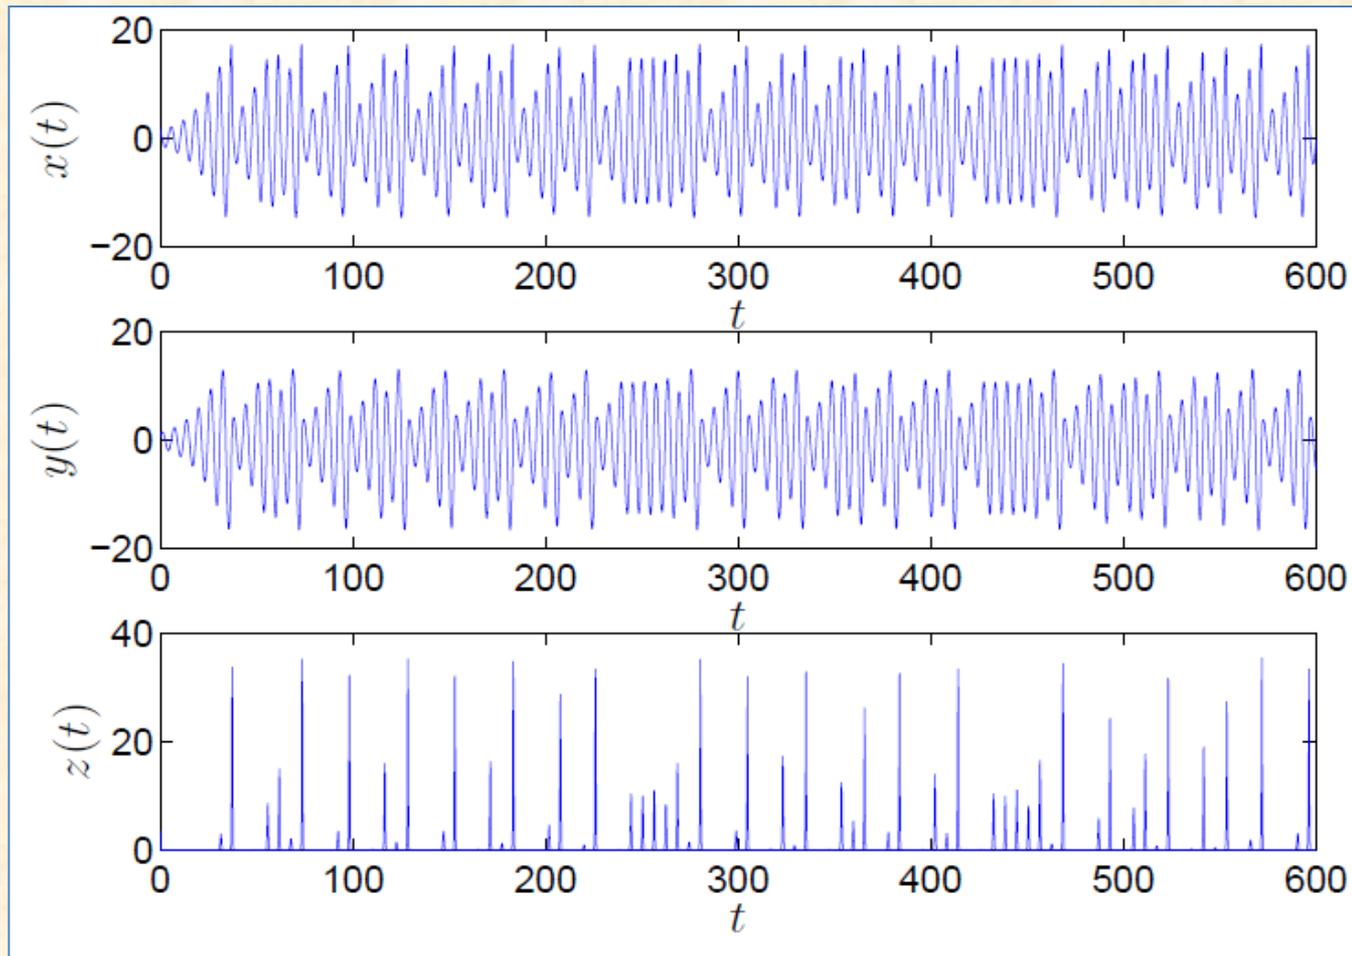
Sincronização por Fase

- Para demonstrar a sincronização por fase utilizaremos osciladores de Rössler, um sistema contínuo de três dimensões proposto pelo pesquisador O.E. Rössler em 1976 :

$$\begin{aligned}\dot{x} &= -y - z, \\ \dot{y} &= x + ay, \\ \dot{z} &= b + z(x - c),\end{aligned}$$

onde (x,y,z) são as variáveis dinâmicas e a , b e c são parâmetros.

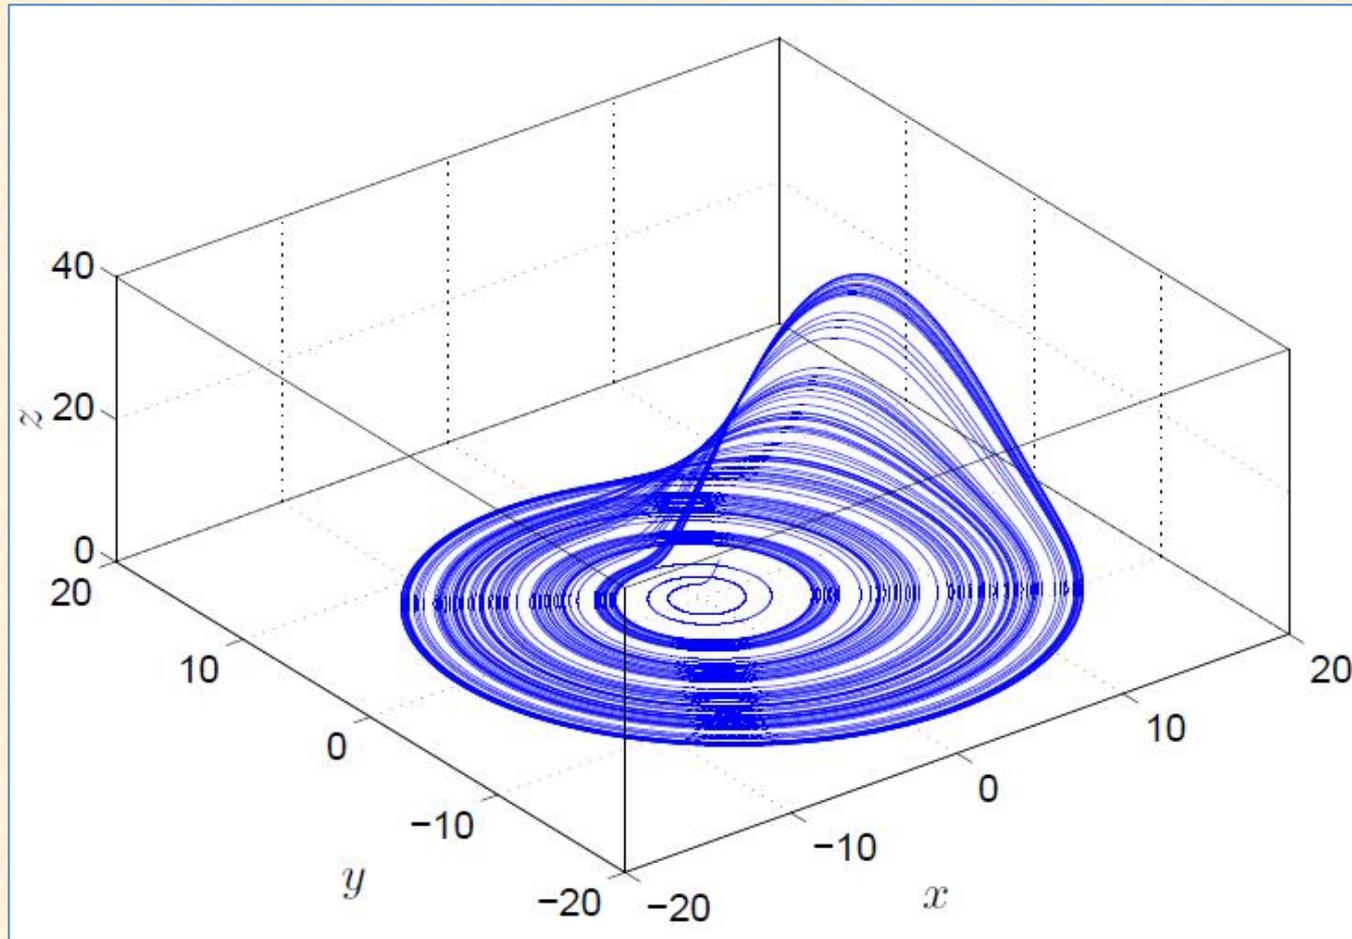
Oscilador de Rössler



$a = 0,15$
 $b = 0,2$
 $c = 10$

Série Temporal das unidades x , y e z de um Oscilador de Rössler

Oscilador de Rössler



$a = 0,15$
 $b = 0,2$
 $c = 10$

Trajétória de fase de um Oscilador de Rössler

Sincronização por Fase

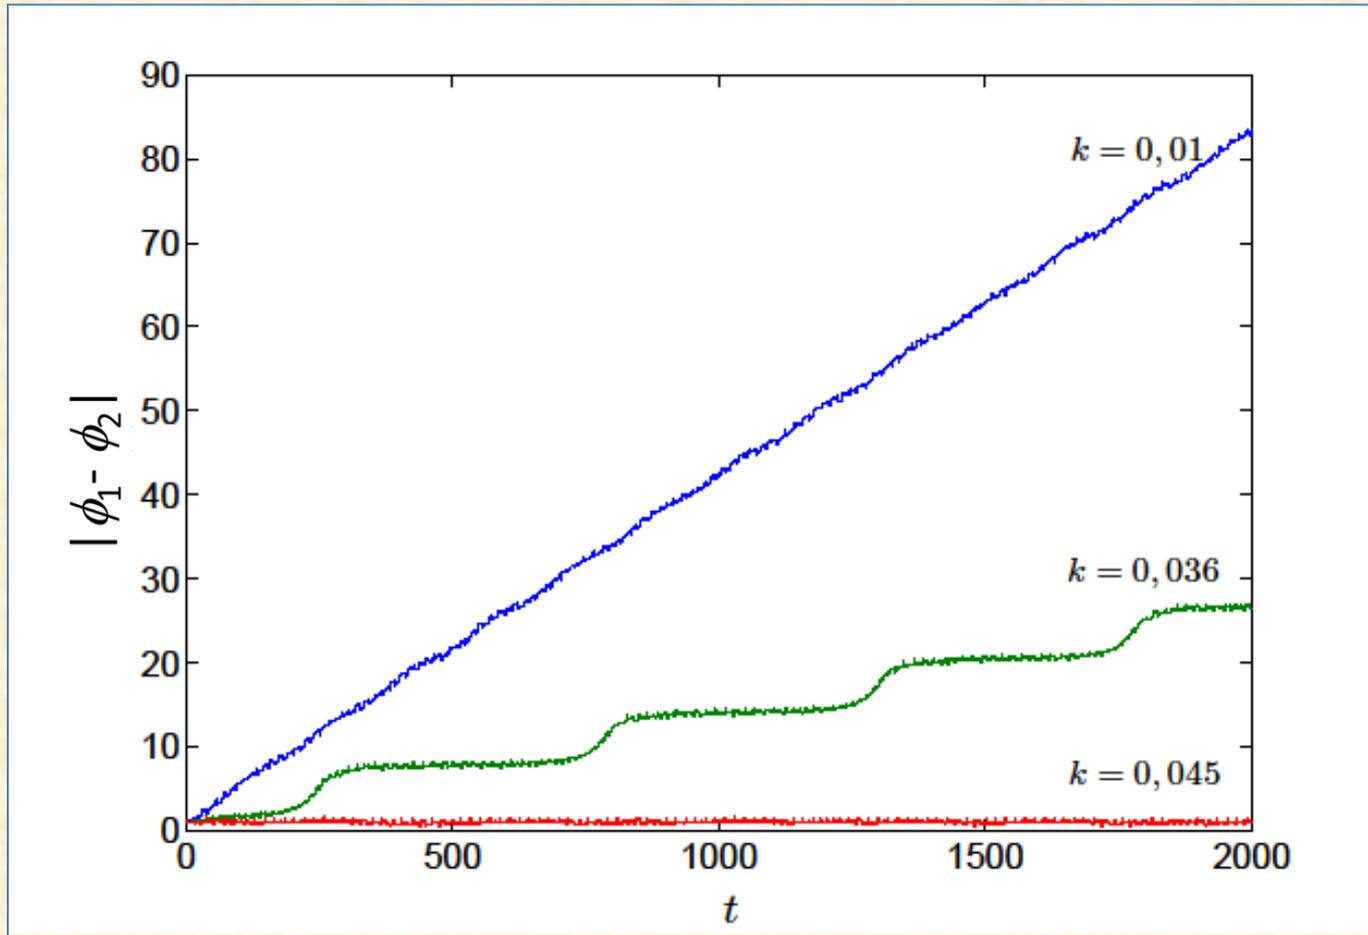
- Exemplo: dois osciladores Rössler acoplados:

$$\begin{aligned}\dot{x}_1 &= -\omega_1 y_1 - z_1 + k(x_2 - x_1), \\ \dot{y}_1 &= \omega_1 x_1 + a y_1, \\ \dot{z}_1 &= b + z_1(x_1 - c), \\ \dot{x}_2 &= -\omega_2 y_2 - z_2 + k(x_1 - x_2), \\ \dot{y}_2 &= \omega_2 x_2 + a y_2, \\ \dot{z}_2 &= b + z_2(x_2 - c),\end{aligned}$$

onde ω governa a diferença de freqüência, de modo que dois osciladores não acoplados, com diferentes valores para ω apresentem freqüências distintas, e k é a força de acoplamento.

Sincronização por Fase

$$\phi = \Upsilon\left(\arctan\left(\frac{y}{x}\right)\right)$$



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 ($k = 0,045$). $\Delta\omega = 0,040$ ($\omega_1 = 0,980$, $\omega_2 = 1,020$).

Alguns modelos baseados em correlação oscilatória

PCNN – Pulse-Coupled Neural Networks

- Em 1989, o pesquisador Eckhorn criou um modelo neural para emular as atividades síncronas observadas em grupos de células neurais do córtex visual do gato
- Em 1994, Johnson adaptou o modelo para o processamento de imagens e chamou o algoritmo de Pulse-Coupled Neural Network.
- As PCNNs tem sido utilizadas para várias tarefas de processamento de imagens, incluindo: segmentação de imagens, extração de fase, detecção de movimento, crescimento de região, redução de ruído, etc.

Eckhorn, R., Reitboeck, H. J., Arndt, M., & Dicke, P. (1990). **Feature linking via synchronization among distributed assemblies: Simulation of results from cat visual cortex.** *Neural Computation*, 2:293–307.

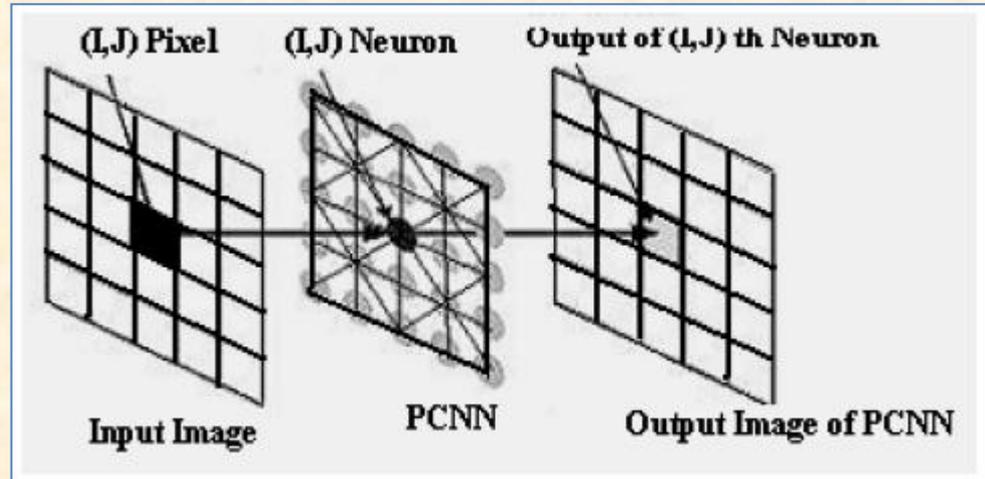
Johnson, J. L. (1994). **Pulse-coupled neural nets: translation, rotation, scale, distortion, and intensity signal invariance for images.** *Applied Optics*, 33(26):6239–6253.

PCNN – Pulse-Coupled Neural Networks

- Rede neural bidimensional
- Cada neurônio representa um pixel da imagem e recebe informação de cor (intensidade) como estímulo externo.
- Cada neurônio se conecta com seus vizinhos e recebe estímulo deles.
- Estímulos externos e locais são combinados em um sistema de ativação interno, o qual acumula estímulo até exceder um limiar dinâmico, resultando em um pulso de saída.
- Estas séries temporais de pulsos tem informações que podem ser utilizadas em diversas tarefas de processamento de imagens

PCNN – Pulse-Coupled Neural Networks

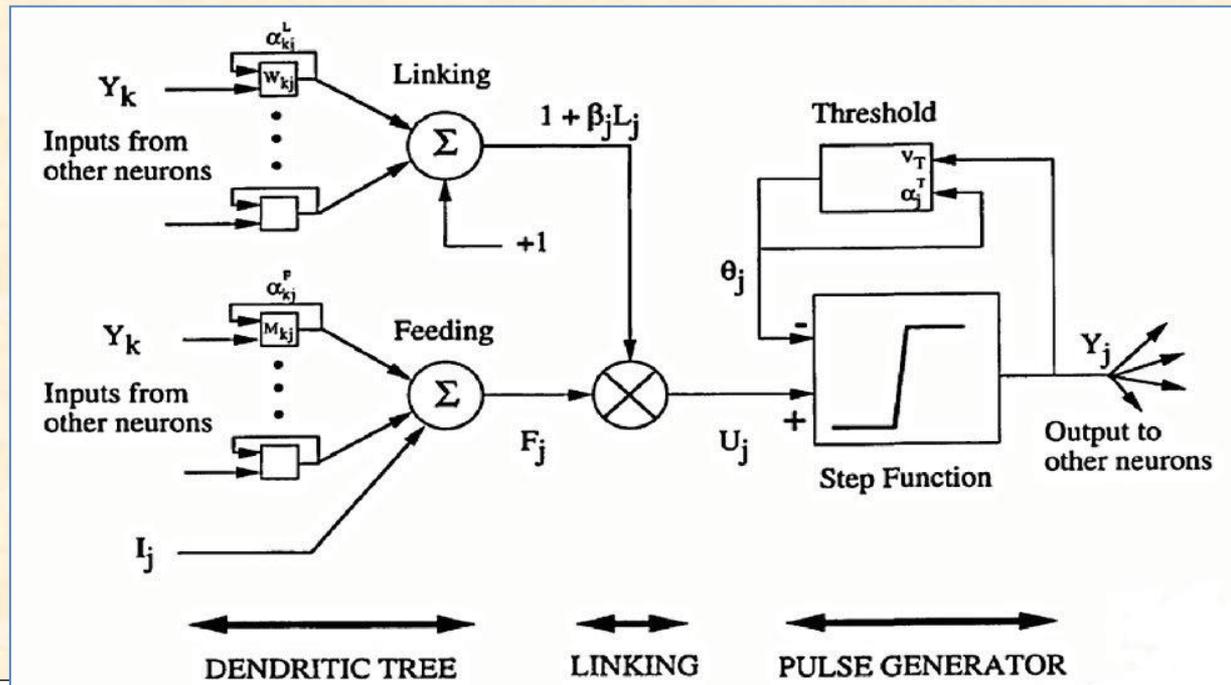
- O modelo de neurônio utilizado possui dois tipos de sinapses dendriticas dinâmicas



- Feeding (entrada primária)
 - Estímulo
- Linking (entrada secundária)
 - Sincronização

$$F_j = \sum_k F_{kj} = \sum_k [M_{kj} e^{-\alpha_{kj}^F t}] * Y_k(t) + I_j$$

$$L_j = \sum_k L_{kj} = \sum_k [W_{kj} e^{-\alpha_{kj}^L t}] * Y_k(t)$$



PCNN – Pulse-Coupled Neural Networks

- Neurônios com entradas similares pulsam em sincronia (segmentação)
- Neurônios com entradas *feeding* similares (cor, intensidade, etc.) possuem frequência de pulsos semelhantes
- As conexões (*linking*) são responsáveis por sincronizar os pulsos de neurônios com características similares que sejam vizinhos

PCNN – Pulse-Coupled Neural Networks

- O Modelo leva em consideração a forma de comunicação observada nos neurônios biológicos (pulsos – potenciais de ação)
- Garante uma maior plausibilidade biológica quando comparada a modelos das primeira e segunda gerações.
- Não possui ajuste de pesos sinápticos (fase de treinamento)

LEGION

- LEGION é um modelo de correlação oscilatória com muitas aplicações reais bem sucedidas, principalmente em segmentação de objetos
 - Posteriormente foi estendido para utilizar neurônios do tipo integra-e-dispara
 - Utiliza osciladores com
 - Acoplamentos excitatórios locais, responsáveis pelo sincronismo entre osciladores representando o mesmo objeto
 - Inibidor global com a finalidade de dessincronizar os grupos de osciladores
 - Mecanismo de cooperação local e competição global

LEGION

- Osciladores compostos de um variável excitatória x_i e uma variável inibitória y_i

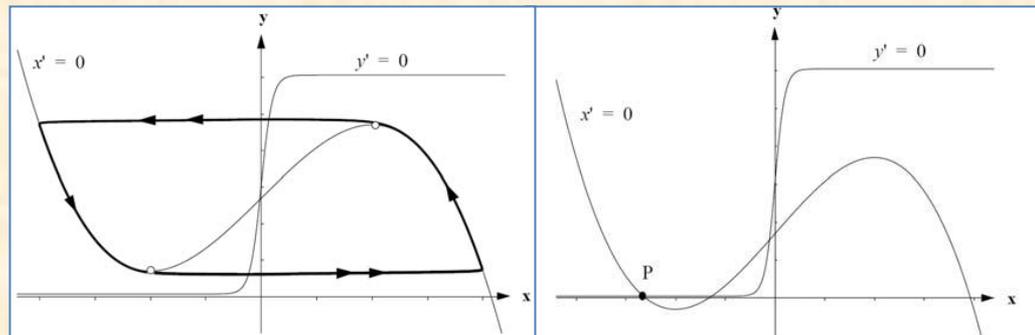
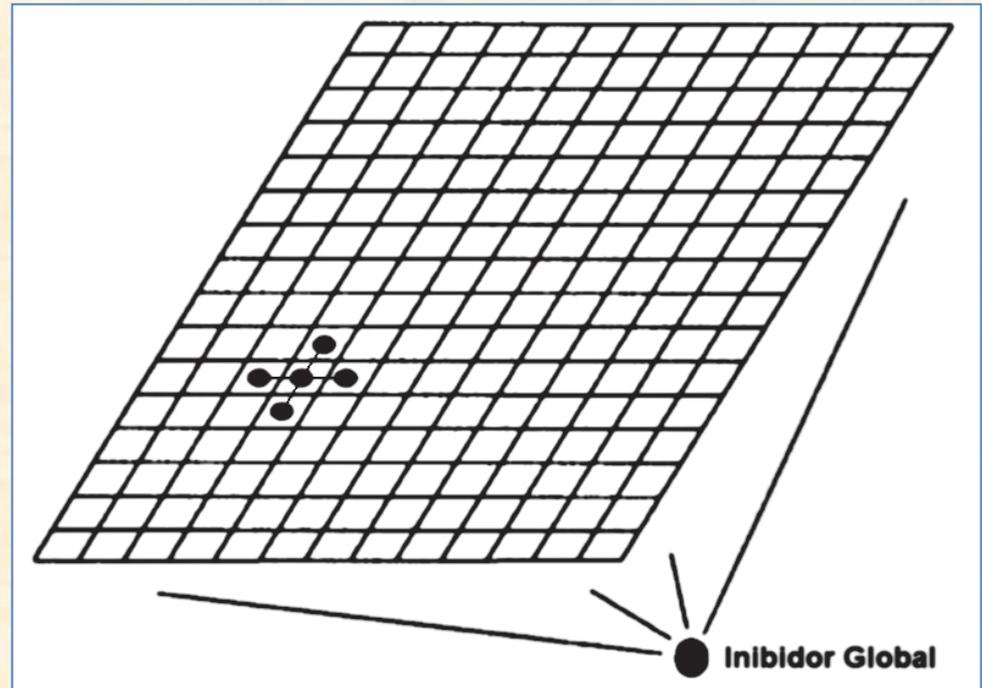
$$\frac{dx_i}{dt} = 3x_i - x_i^3 + 2 - y_i + \rho + I_i + S_i$$

$$\frac{dy_i}{dt} = \epsilon \left(\gamma \left(1 + \tanh \left(\frac{x_i}{\beta} \right) \right) - y_i \right)$$

I_i é o estímulo externo ao elemento i
 S_i define o acoplamento com os demais elementos da rede

ϵ é uma constante positiva com valor pequeno

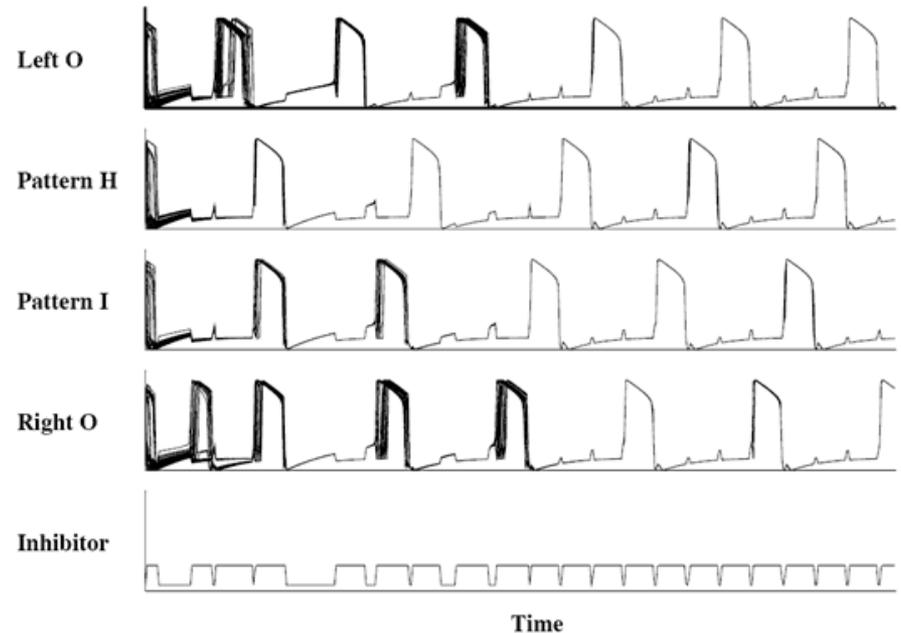
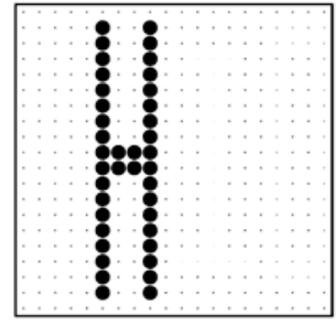
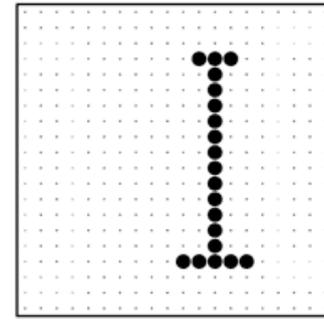
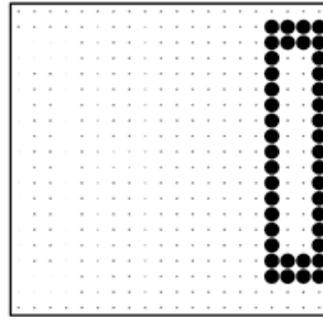
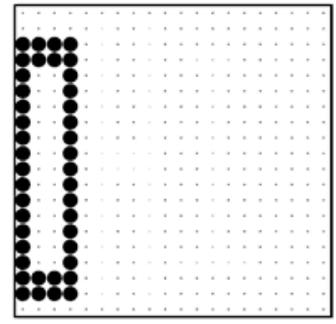
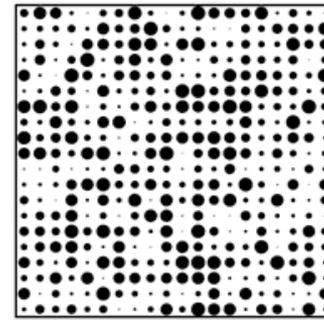
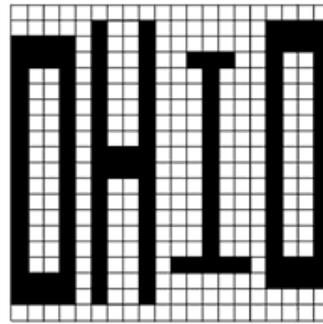
ρ representa um sinal de ruído



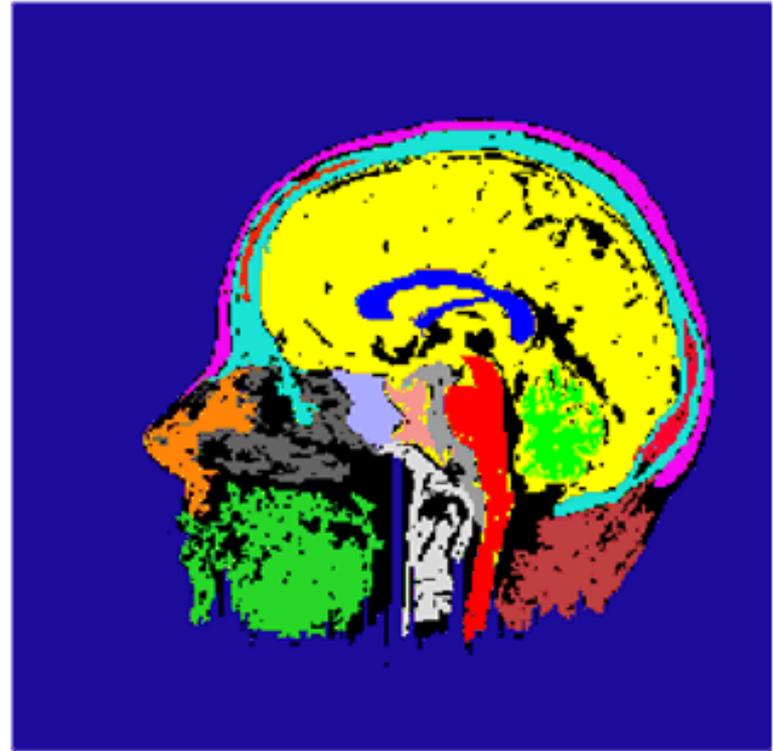
Dinâmica de um oscilador de relaxamento utilizado no modelo LEGION (Terman & Wang, 1995). (a) Dinâmica de Ciclo Limite quando $I_i > 0$; (b) Dinâmica Estacionária quando $I_i < 0$.

LEGION

- No primeiro quadro a cena de entrada com quatro padrões conectados em um grid 20x20
- No segundo quadro um instantâneo da atividade da rede no início da evolução dinâmica, onde o diâmetro de cada círculo indica a atividade do oscilador correspondente.
- Instantâneos subseqüentes são mostrados nos demais quadros
- Painel de baixo mostra atividade temporal dos quatro grupos de osciladores.



LEGION



Modelo Dinâmico de Clusterização de Dados

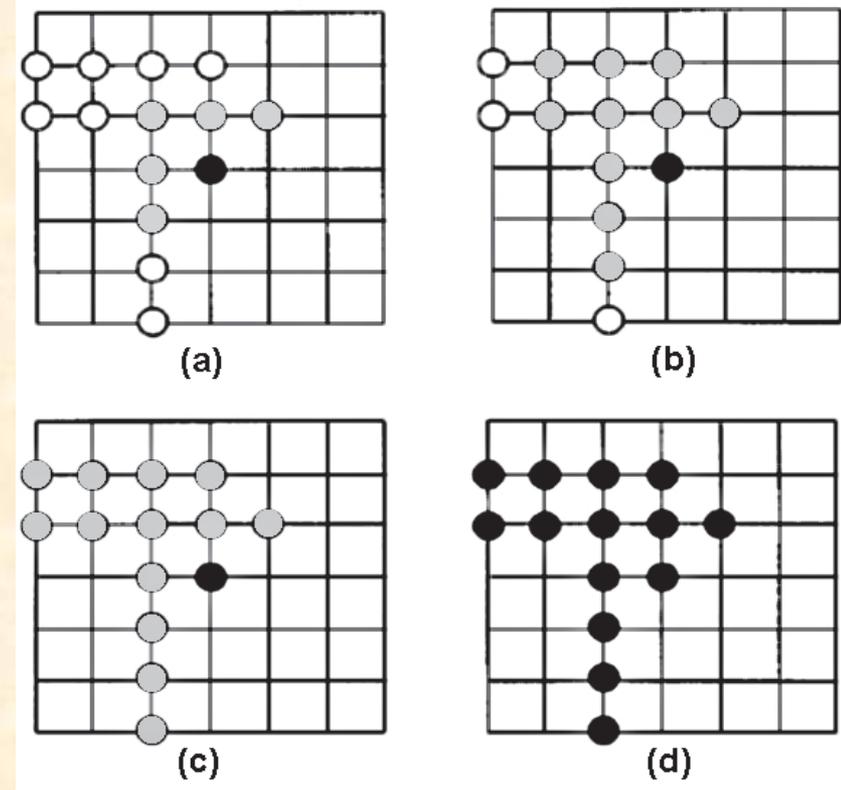
- Modelo de clusterização que utiliza mapas caóticos acoplados (Correlação Oscilatória Caótica)
 - Cada elemento da rede é representado por um mapa caótico, que corresponde a um elemento no espaço de atributos
- Elementos se auto-organizam de acordo com um critério de similaridade pré-definido
 - Elementos que representam um mesmo cluster tem acoplamento mantido
 - Elementos que representam diferentes clusters terão seus respectivos acoplamentos eliminados

Zhao, L., A. de Carvalho, & Z. Li (2004, Sep). **Pixel clustering by adaptive moving and chaotic synchronization**. *Neural Networks, IEEE Transactions on* 15(5), 1176–1185.

Zhao, L., Damiance, A. P. G., & de Carvalho, A. C. P. L. F. (2005). **A self-organized network for data clustering**. In L. Wang, K. Chen, & Y.-S. Ong (Eds.), *ICNC (1)*, volume 3610 of *Lecture Notes in Computer Science* (pp. 1189–1198).: Springer.

Modelo Dinâmico de Clusterização de Dados

- Elementos pertencentes a um mesmo cluster serão sincronizados
 - Após um período transiente cada elemento será representado por uma trajetória caótica sincronizada com a dos demais elementos
- Elementos de clusters diferentes terão diferentes trajetórias caóticas
 - Devido a alta sensibilidade as condições iniciais e propriedades densas do caos



Acoplamento dos mapas caóticos presentes na rede. (a) instante inicial ($t = 0$); (b) $t = 1$; (c) $t = 2$; (d) todos os elementos ativos de um mesmo objeto acoplados

Segmentação com Osciladores Wilson-Cowan

- Segmentação de Imagens com Sistemas Caóticos e Sincronização
 - Baseado no Sistema Dinâmico
 - Osciladores representando pixels do mesmo objeto são sincronizados formando trajetórias idênticas
 - Osciladores representando pixels de objetos diferentes são dessincronizados e apresentam trajetórias diferentes
 - Biologicamente plausível
 - Experimentos fisiológicos apontam forte evidência da existência de atividades rítmicas sincronizadas em diferentes áreas do cérebro de seres humanos, gatos e macacos

Segmentação com Osciladores Wilson-Cowan

- Segmentação de Imagens com Oscilador Wilson-Cowan e Sincronização Completa
 - Grade de osciladores Wilson-Cowan
 - Cada oscilador representa um pixel da imagem

$$\begin{aligned}\dot{x}_{i,j} &= -ax_{i,j} + G(cx_{i,j} + ey_{i,j} + I_{i,j} - \theta_x) + k\Delta x_{i,j}, \\ \dot{y}_{i,j} &= -by_{i,j} + G(dx_{i,j} + fy_{i,j} - \theta_y) + k\Delta y_{i,j}, \\ G(v) &= \frac{1}{1 + e^{-(v/T)}},\end{aligned}$$

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

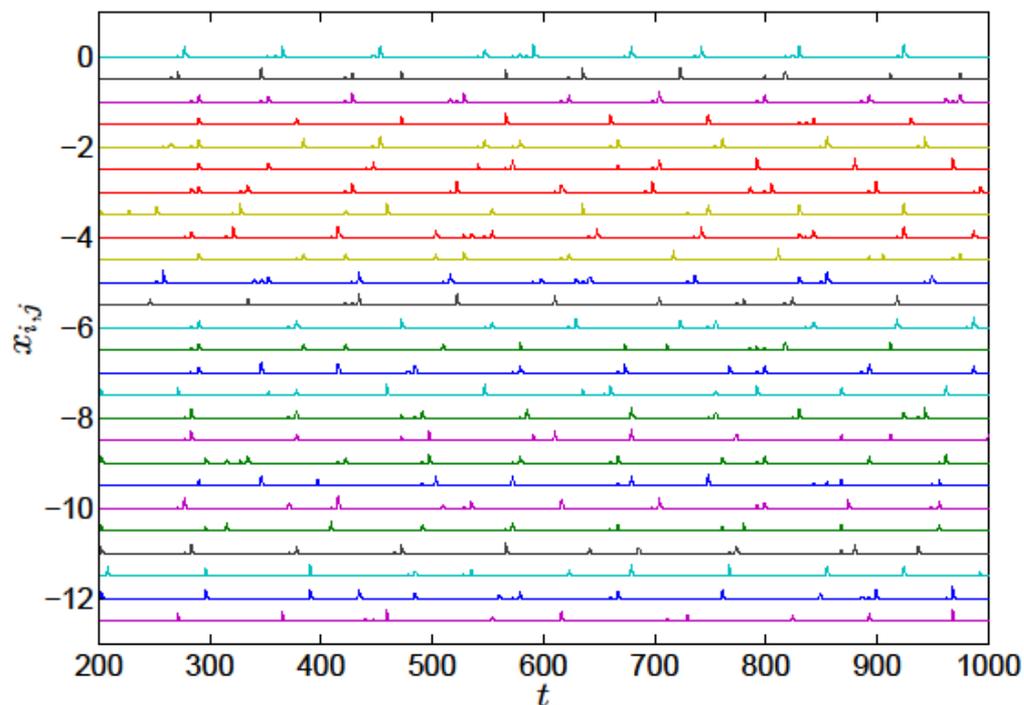
- k é a força de acoplamento
- (i,j) é um ponto na grade
- Estímulo externo I é dado por $I_{i,j}(t) = A_{i,j} \cos(t)$
- $A_{i,j}$ recebe valores proporcionais ao nível de cinza do pixel de entrada

$$\gamma_{i,j;p,q} = \begin{cases} 1, & \text{se o elemento } (i,j) \text{ está acoplado com } (p,q), \\ 0, & \text{caso contrário.} \end{cases}$$

Segmentação com Osciladores Wilson-Cowan

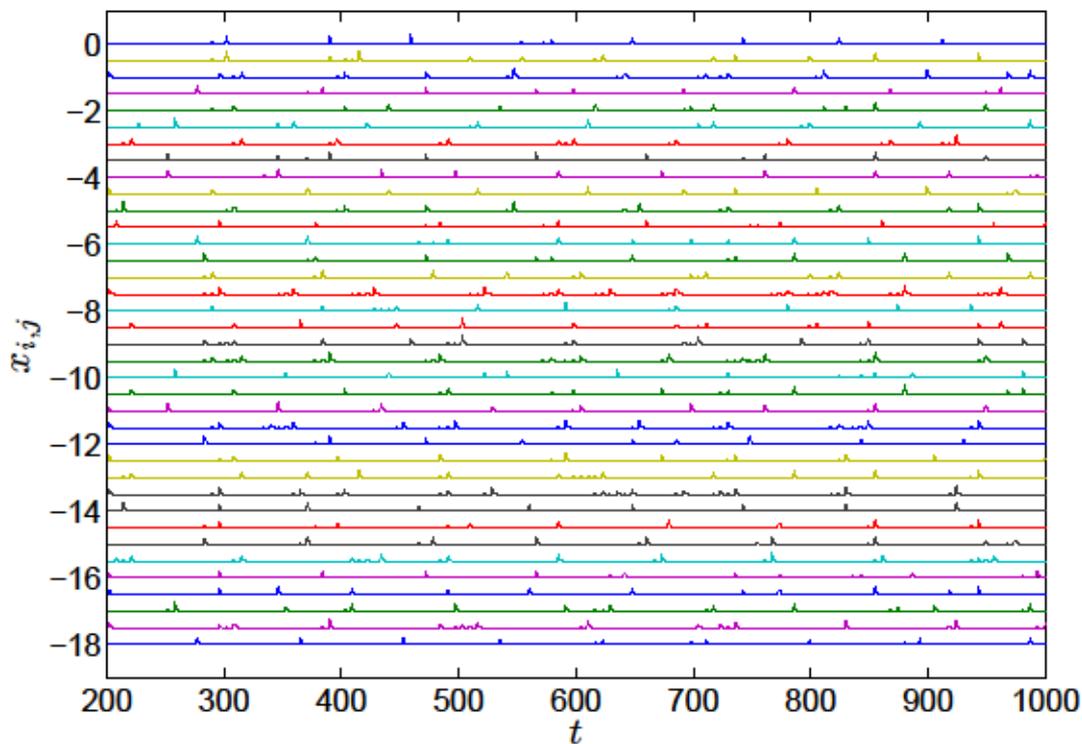


- Imagem artificial para segmentação com 26 letras, 144x90 pixels



Segmentação com Osciladores Wilson-Cowan

- Imagem real para segmentação com 37 objetos diversos, 320x240 pixels



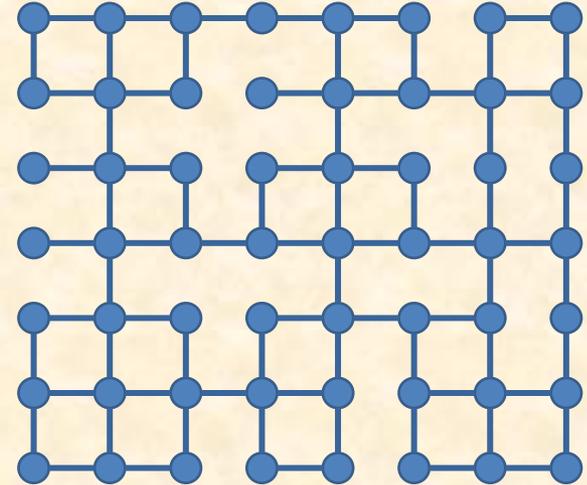
Atenção Visual com Sincronização por Fase em Redes de Osciladores

- 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 ω

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

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 ω
- Objeto saliente passa de dinâmica caótica para periódica e crescimento de fase maior que os demais

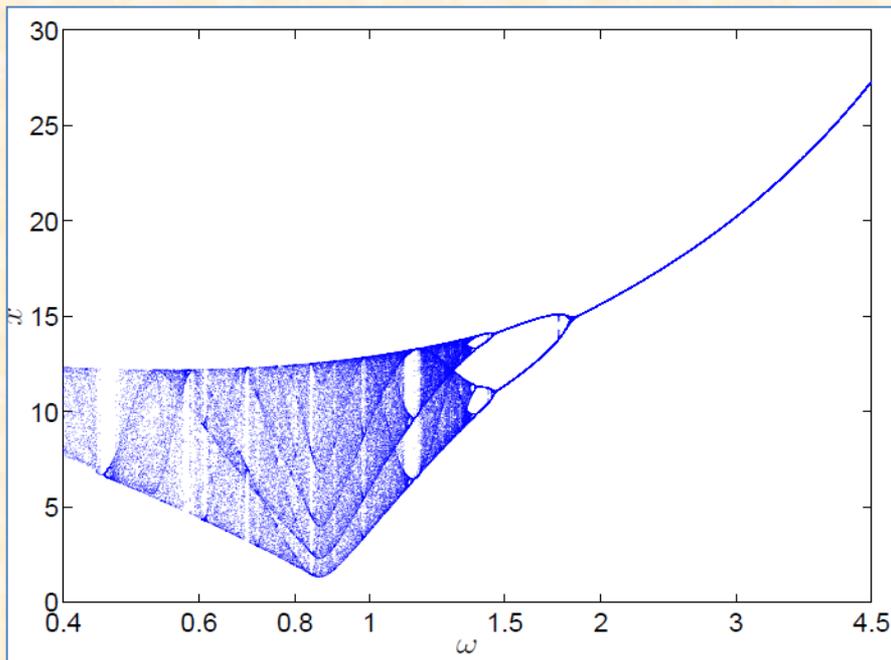
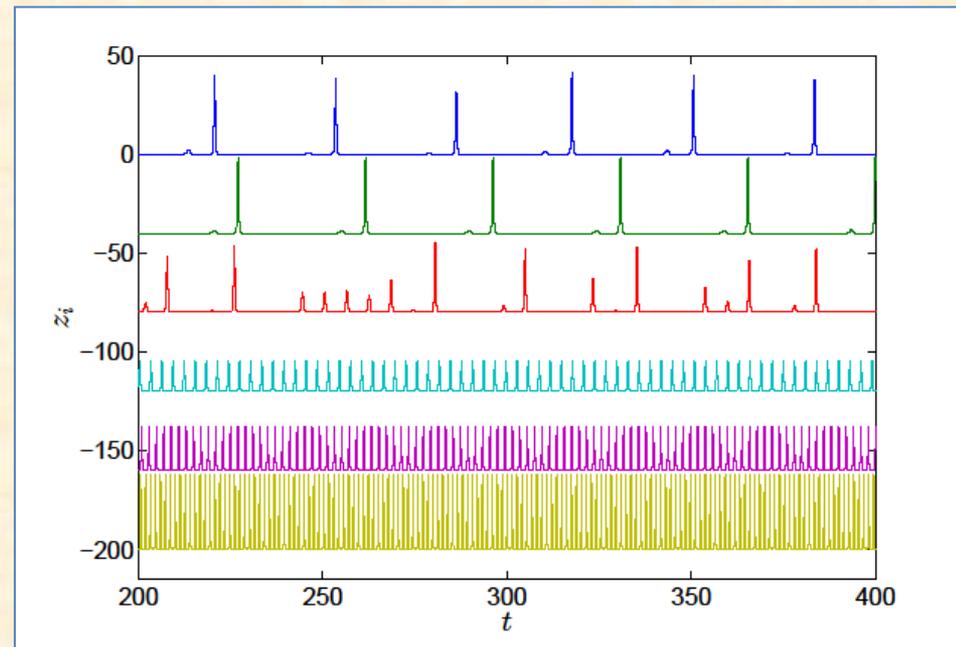
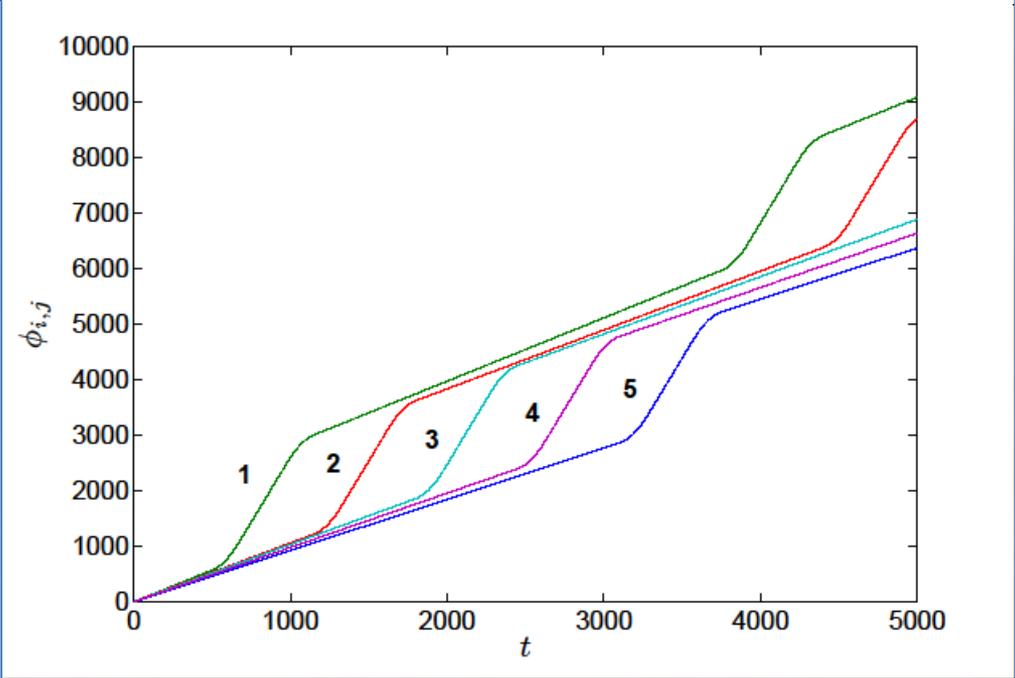
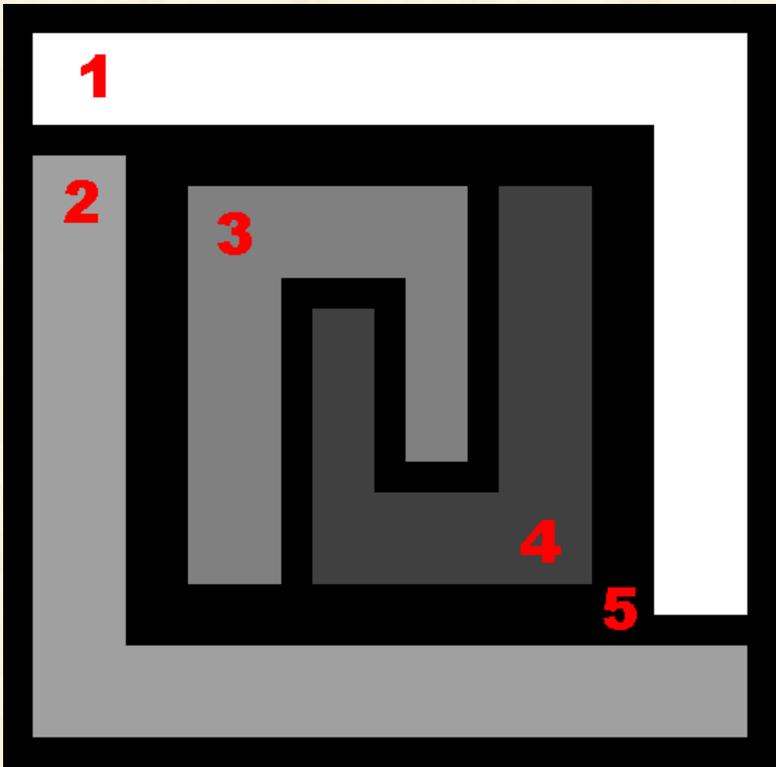


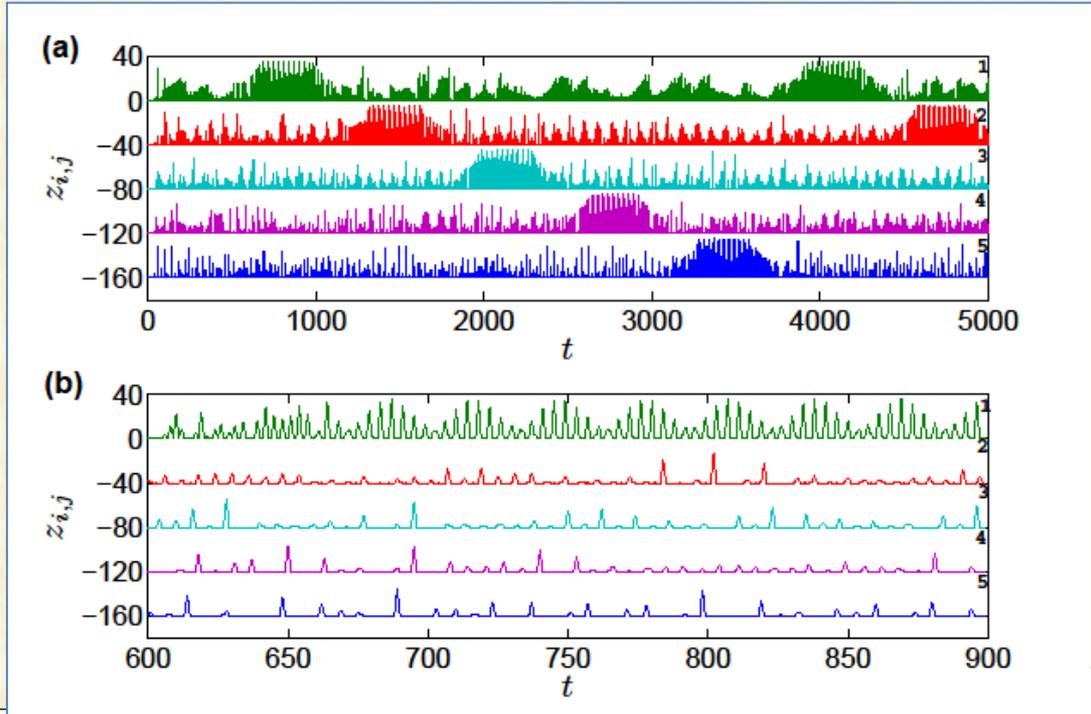
Diagrama de bifurcação de um oscilador Rössler variando o parâmetro ω

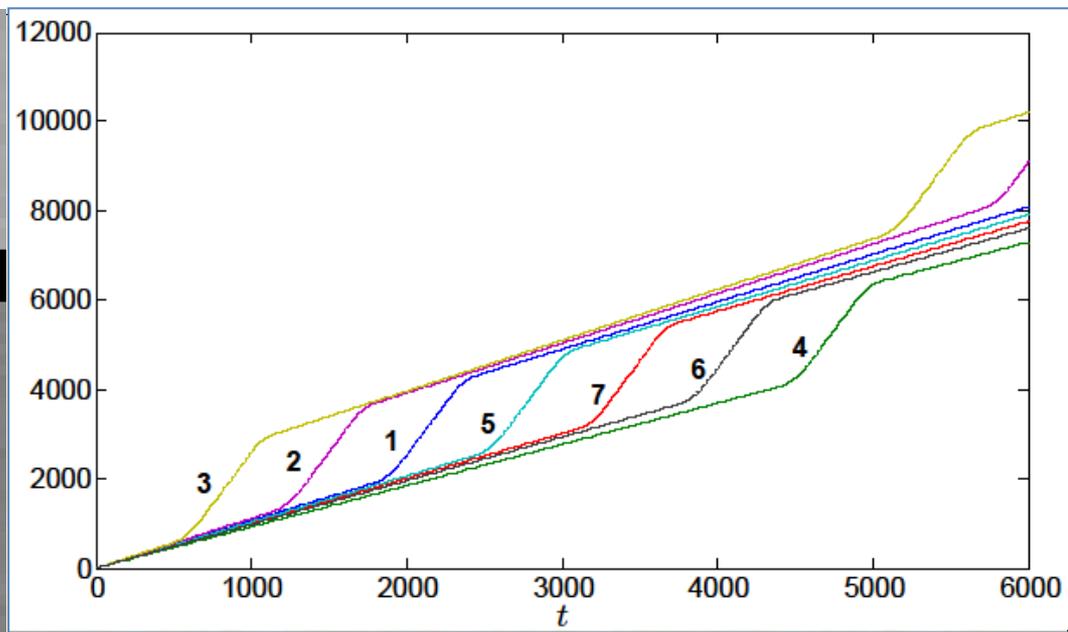
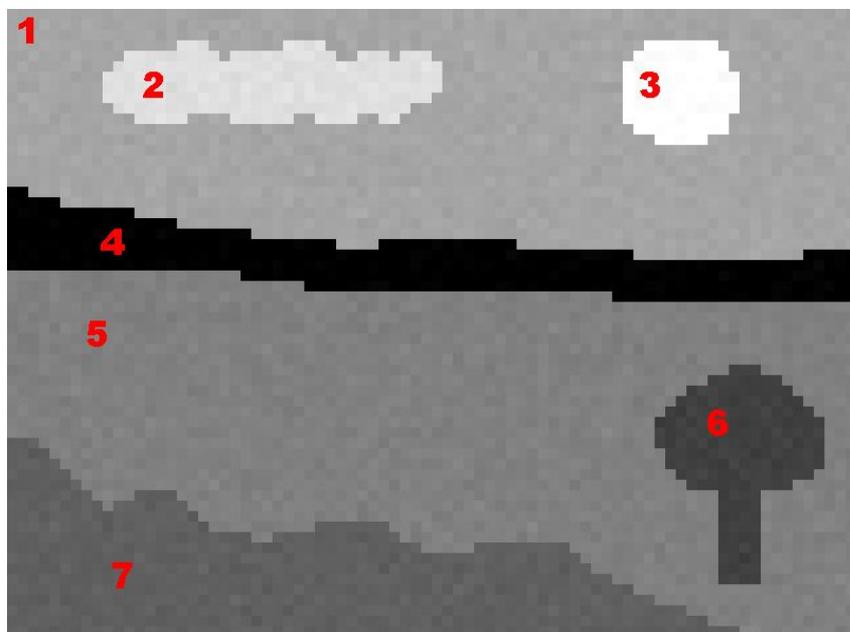


Atividades temporais de osciladores Rössler com $\omega=0,8$; $\omega=0,9$; $\omega=1,0$; $\omega=2,0$; $\omega=3,0$; e $\omega=4,5$ respectivamente.

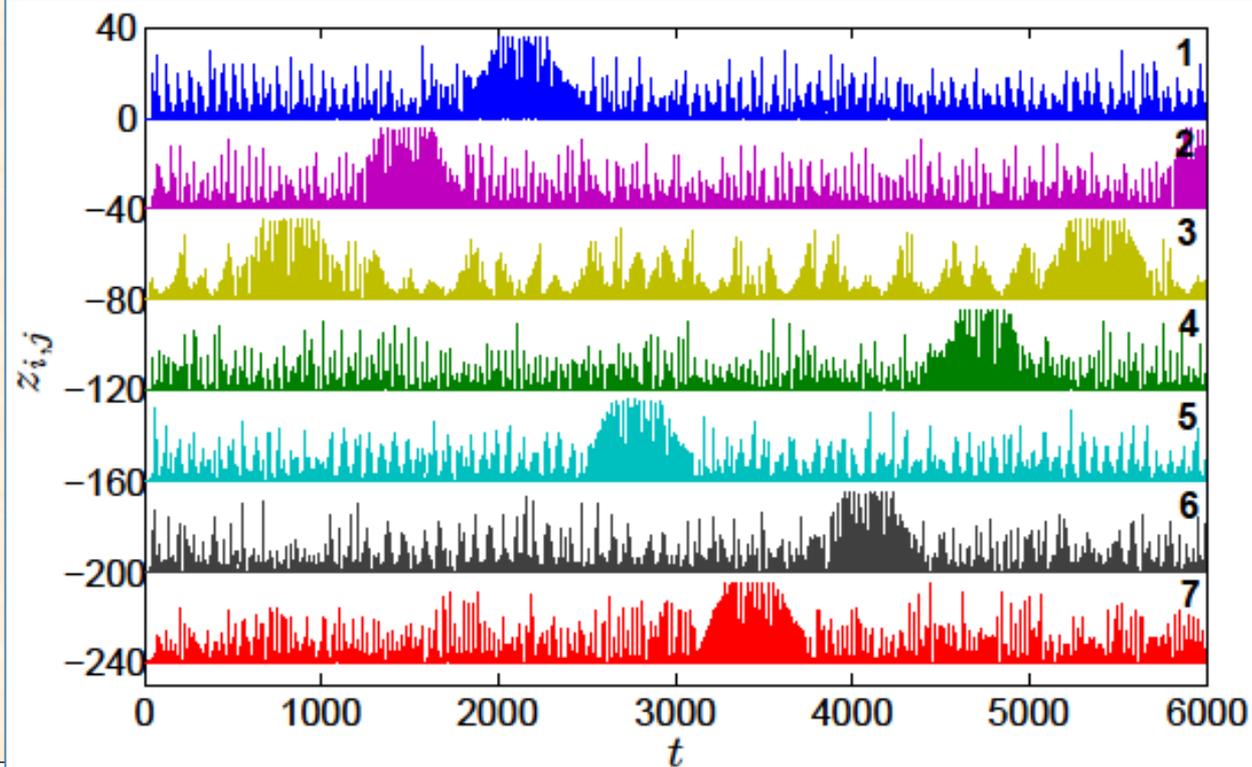


Atenção visual em imagem artificial com 5 objetos linearmente não separáveis (incluindo o fundo), 25 x 25 pixels: (a) Imagem original; (b) Medida de fase dos blocos de osciladores. Cada trajetória na figura representa um grupo de osciladores sincronizados por fase e corresponde a um segmento da imagem 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.

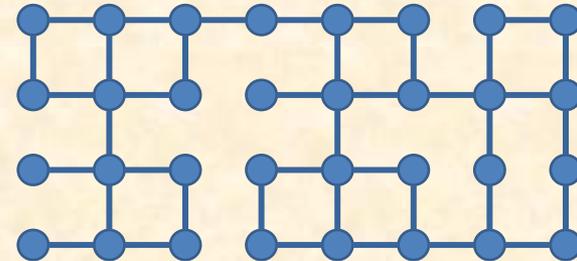
Breve, F. A., Zhao, L., Quiles, M. G., & Macau, E. E. N. (2009d). **Chaotic phase synchronization for visual selection.** *IEEE - INNS - ENNS International Joint Conference on Neural Networks*, (pp. 383–390).

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

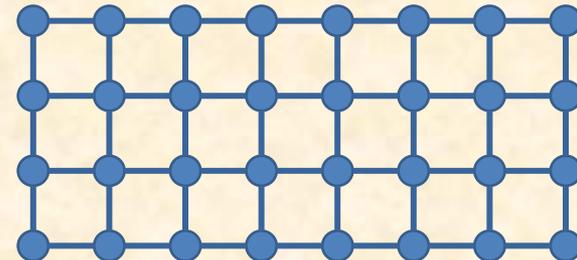
$$\begin{aligned}\dot{x}_{i,j} &= -\omega_{i,j}y_{i,j} - z_{i,j} + k_{i,j}^+ \Delta^+ x_{i,j} + k_{i,j}^- \Delta^- x_{i,j}, \\ \dot{y}_{i,j} &= \omega_{i,j}x_{i,j} + ay_{i,j}, \\ \dot{z}_{i,j} &= b + z_{i,j}(x_{i,j} - c).\end{aligned}$$

- 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 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**

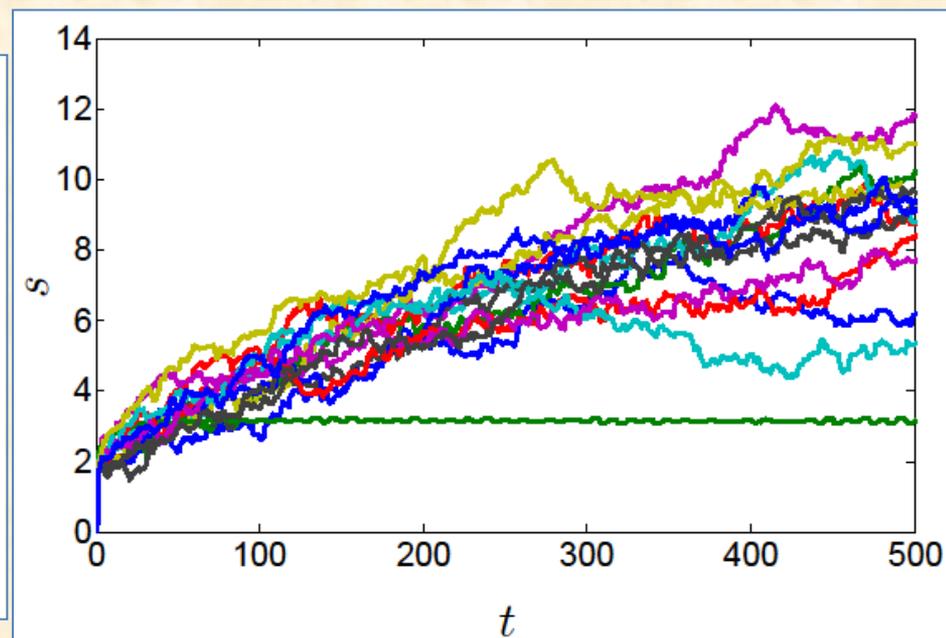
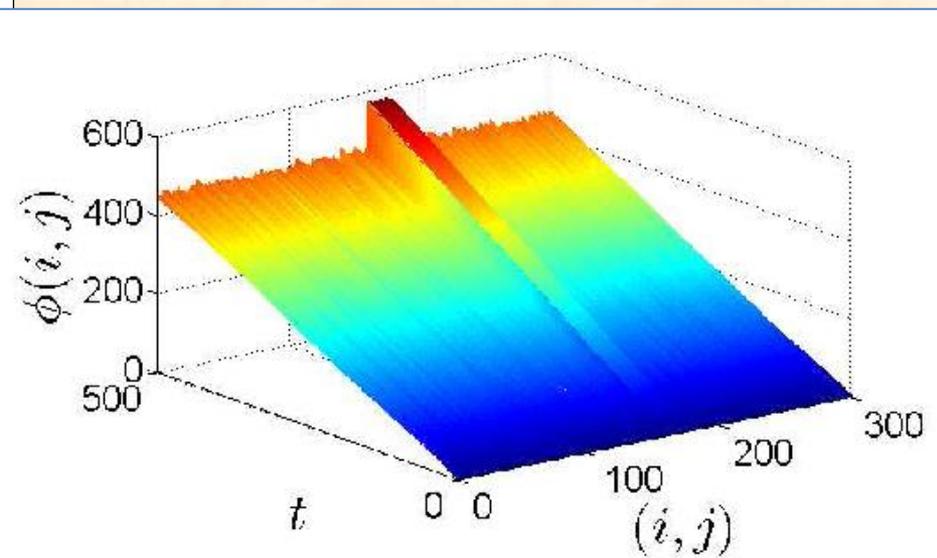
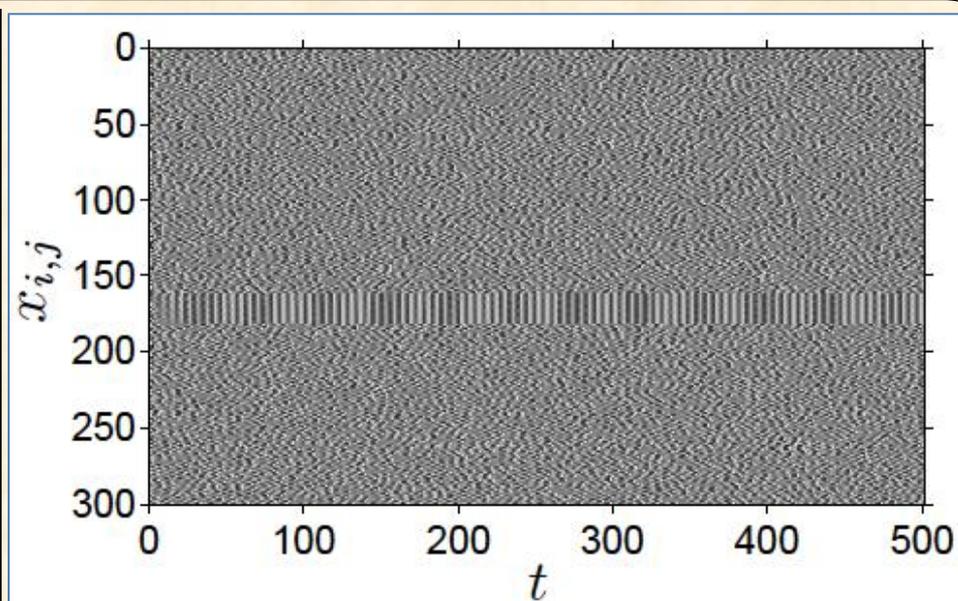
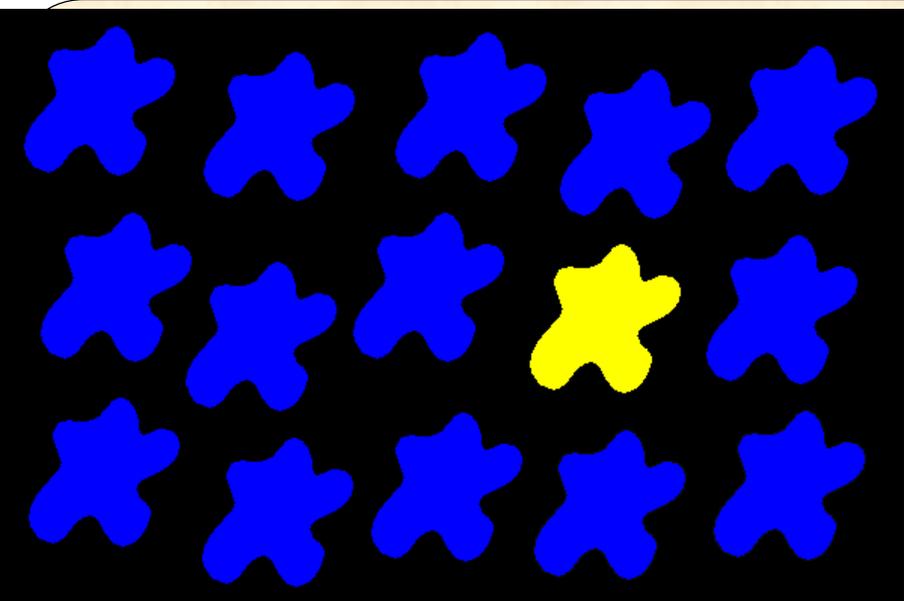


- **Conexões negativas estão sempre ligadas**

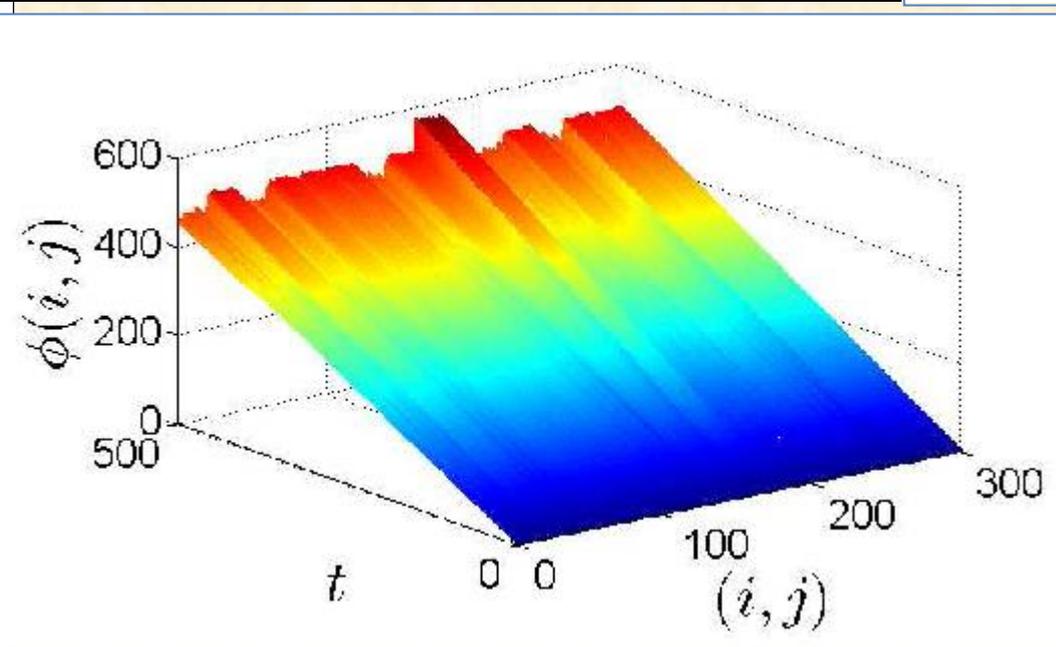
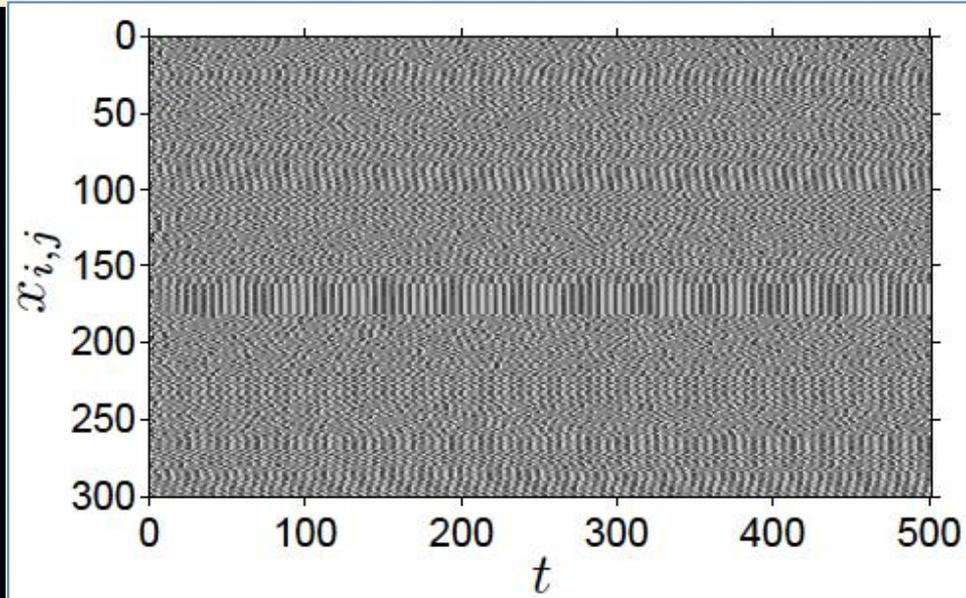
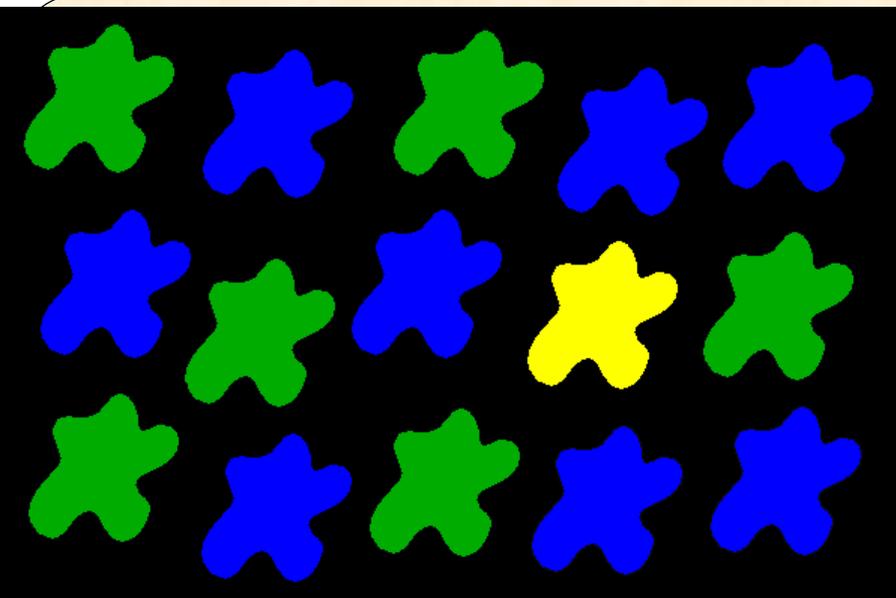


Atenção Visual com Sincronização e Dessincronização por Fase em Redes de Osciladores

- 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.*
 - **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.



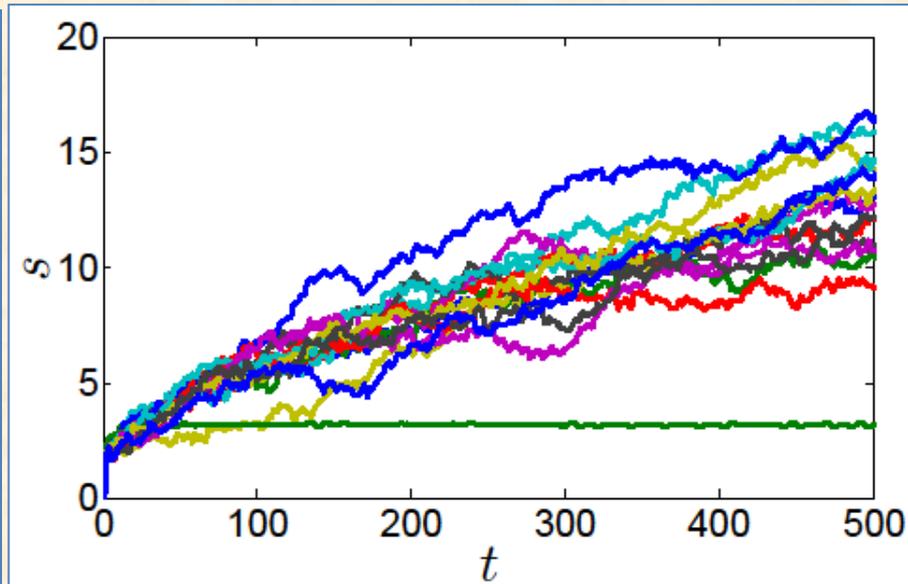
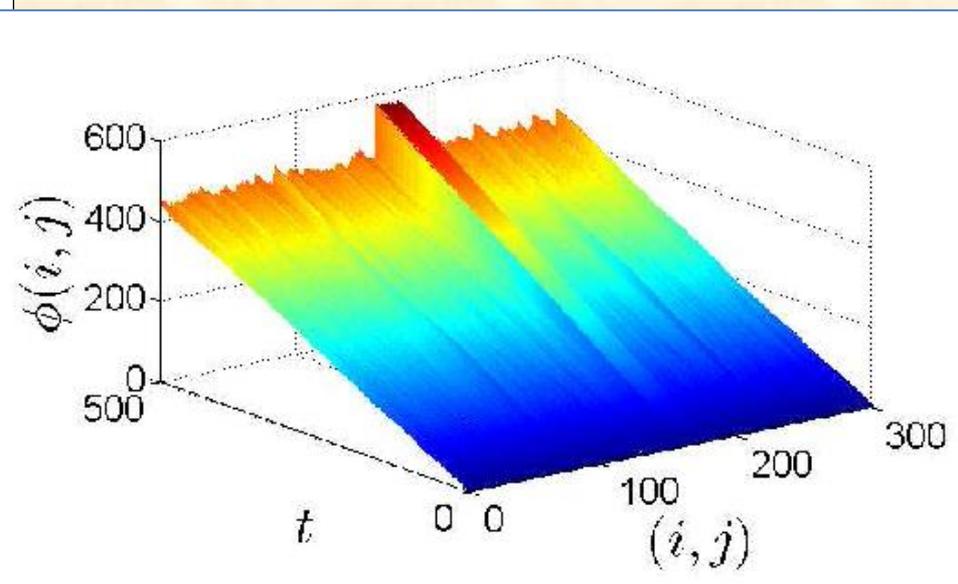
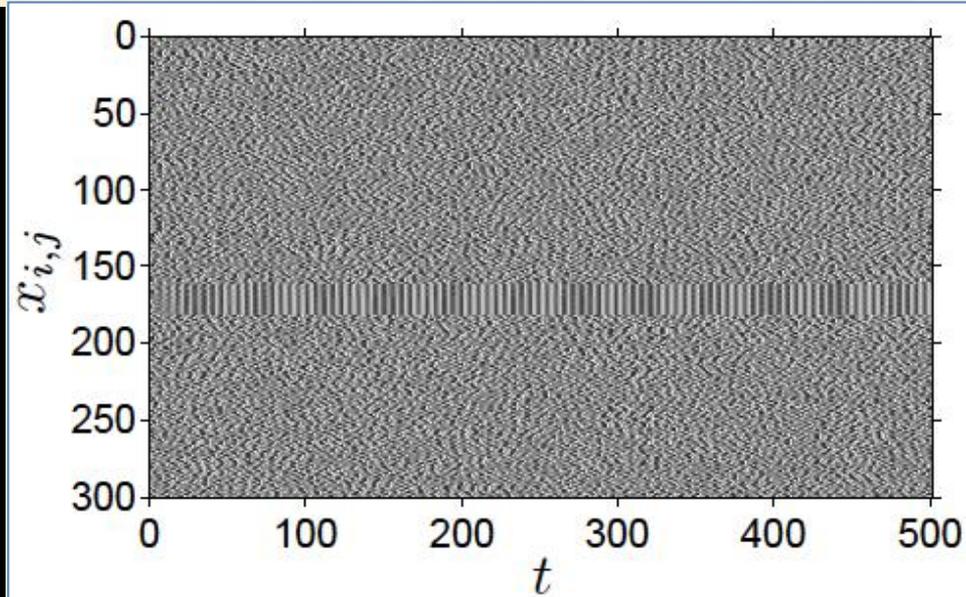
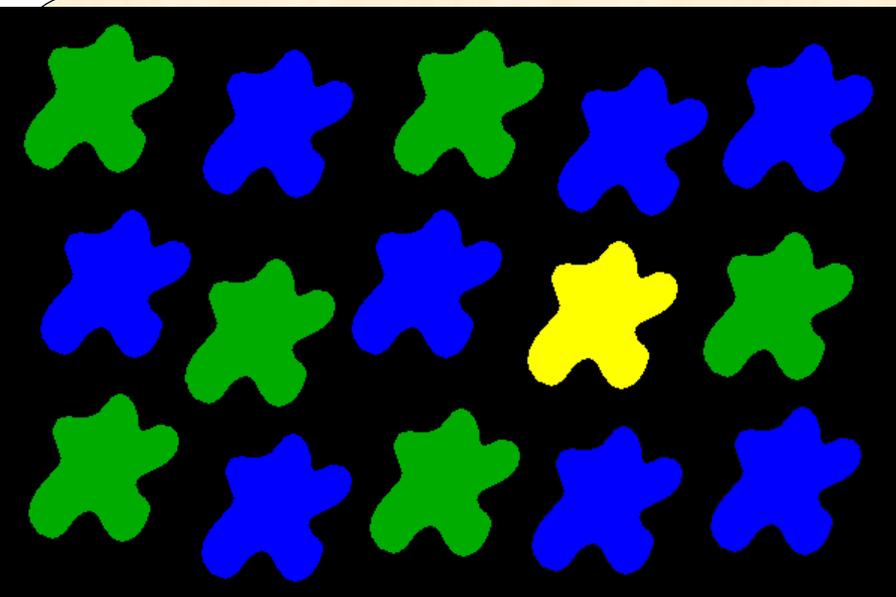
(a) Imagem artificial com alto contraste; (b) Comportamento dos osciladores;
 (c) Crescimento de fase; (d) Séries temporais do desvio-padrão de fase de cada objeto;



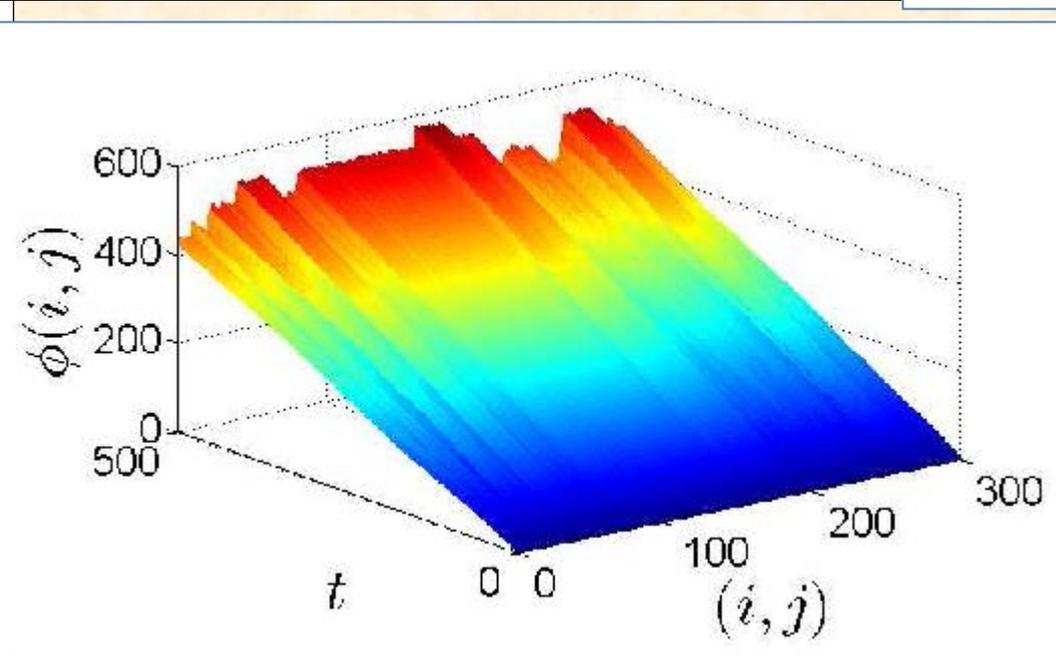
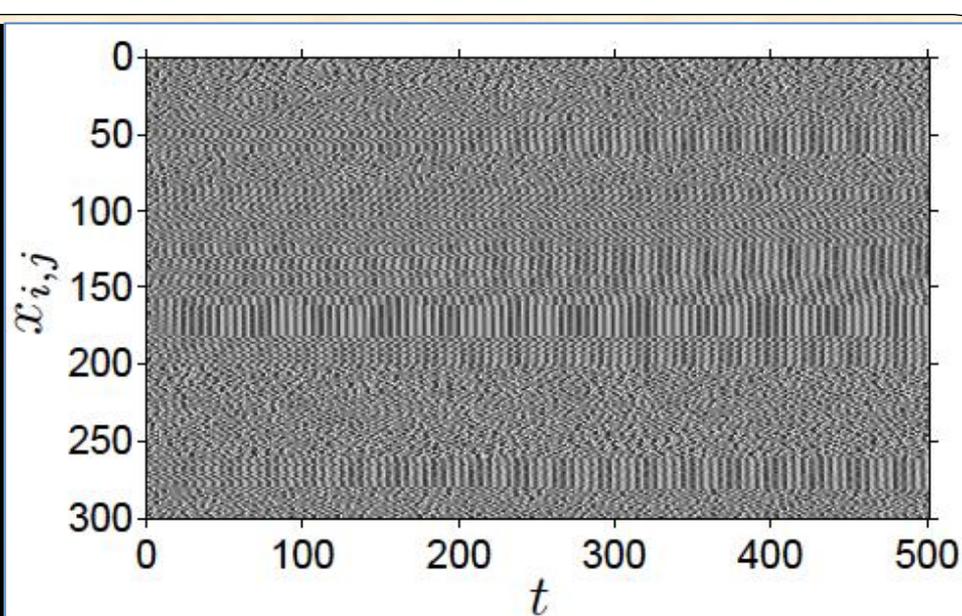
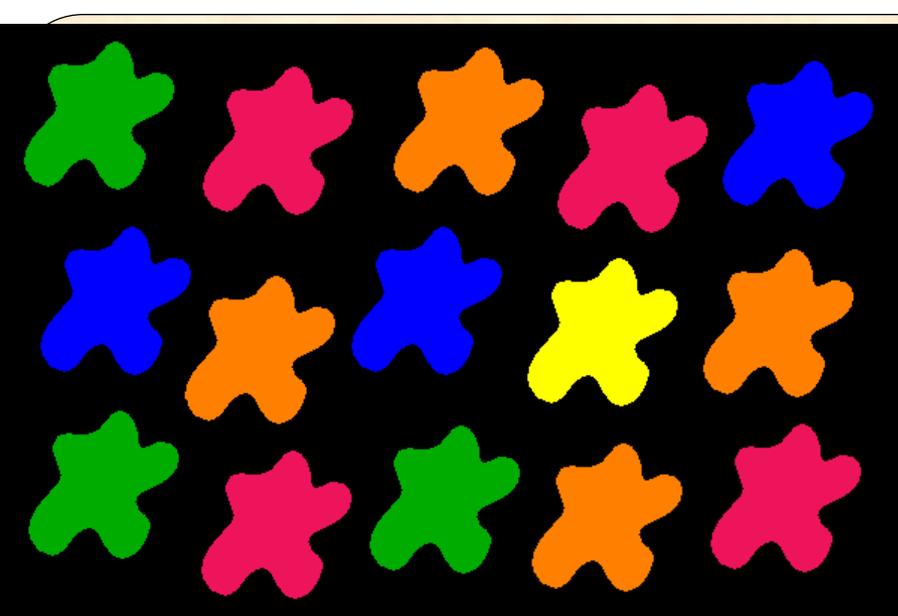
$$R_{i,j} = \exp\left(-\frac{(1 - C_{i,j})^2}{2\sigma^2}\right)$$

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

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



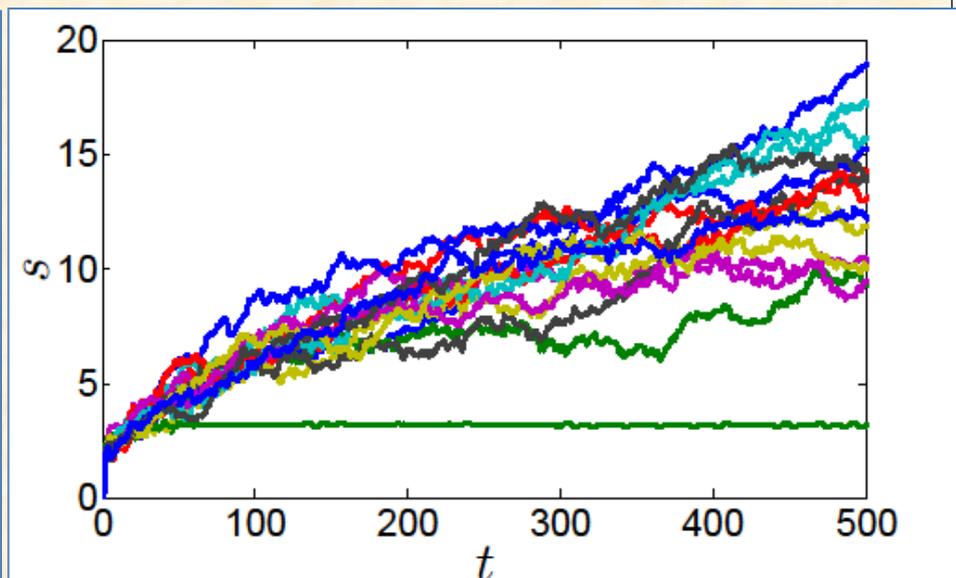
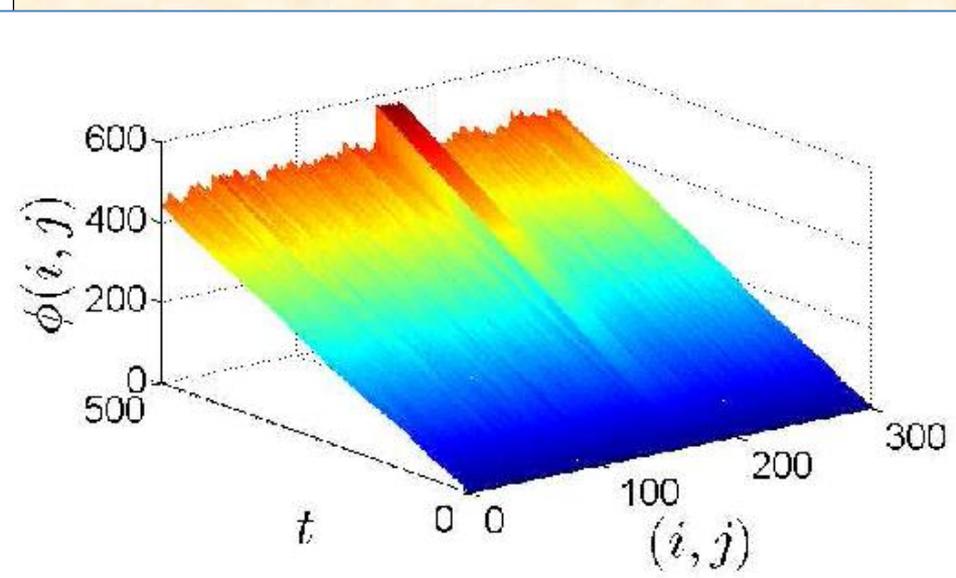
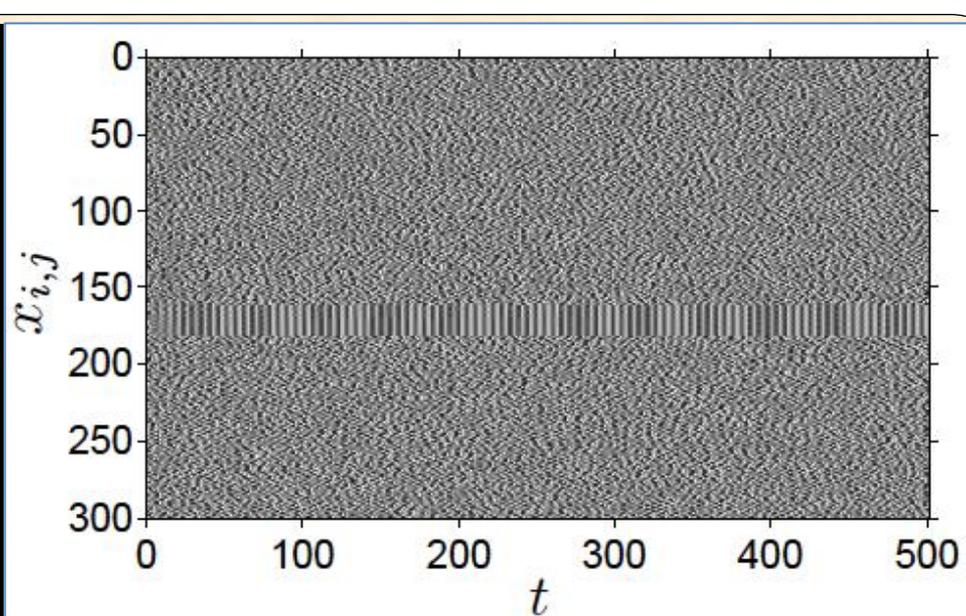
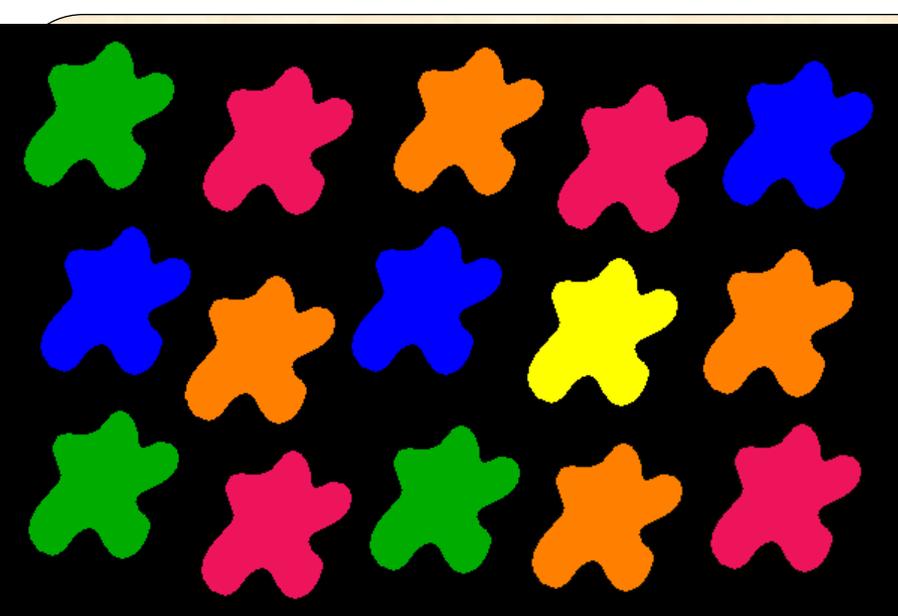
(a) Imagem artificial com médio contraste; (b) Comportamento dos osciladores, $\sigma=0,25$;
 (c) Crescimento de fase, $\sigma=0,25$; (d) Séries temporais do desvio-padrão de fase de cada objeto;



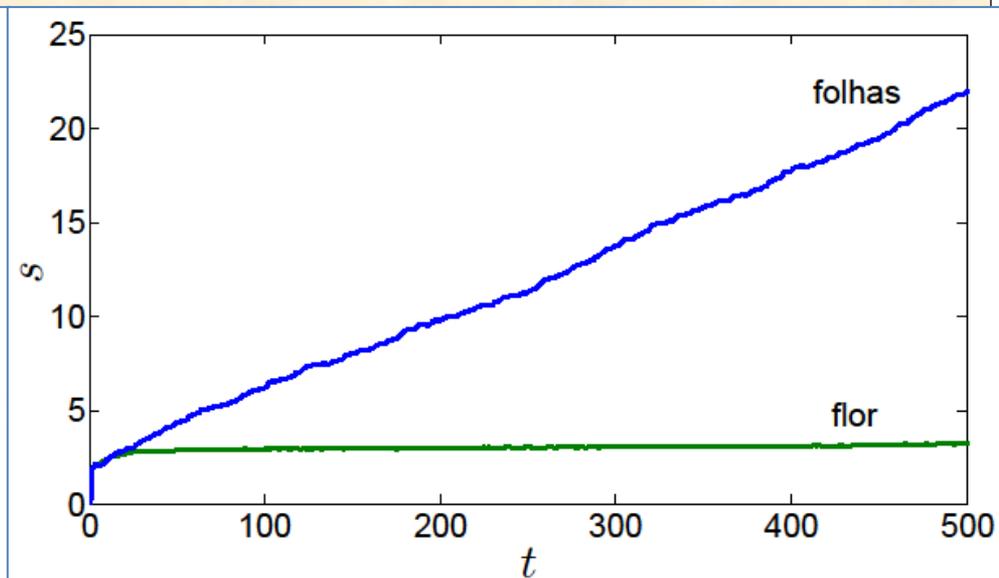
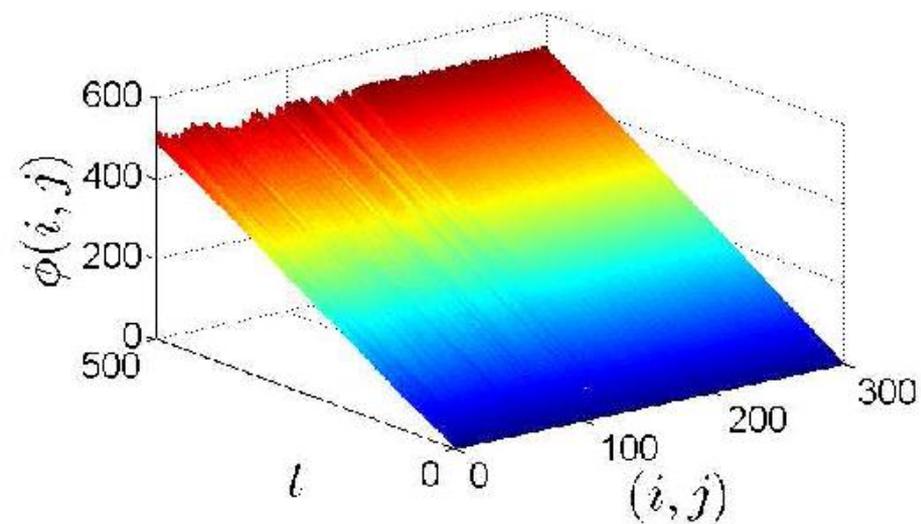
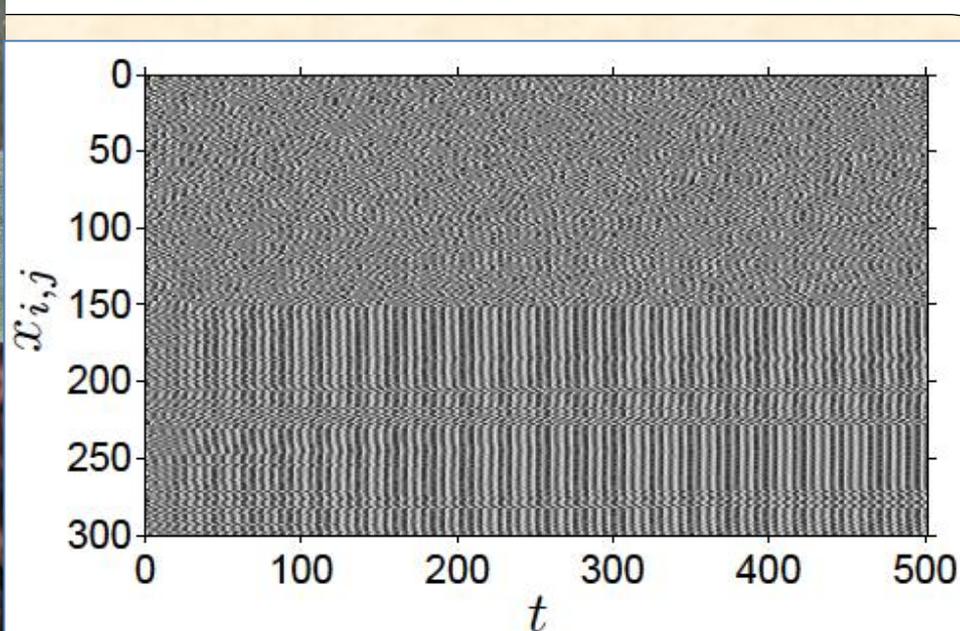
$$R_{i,j} = \exp\left(-\frac{(1 - C_{i,j})^2}{2\sigma^2}\right)$$

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

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

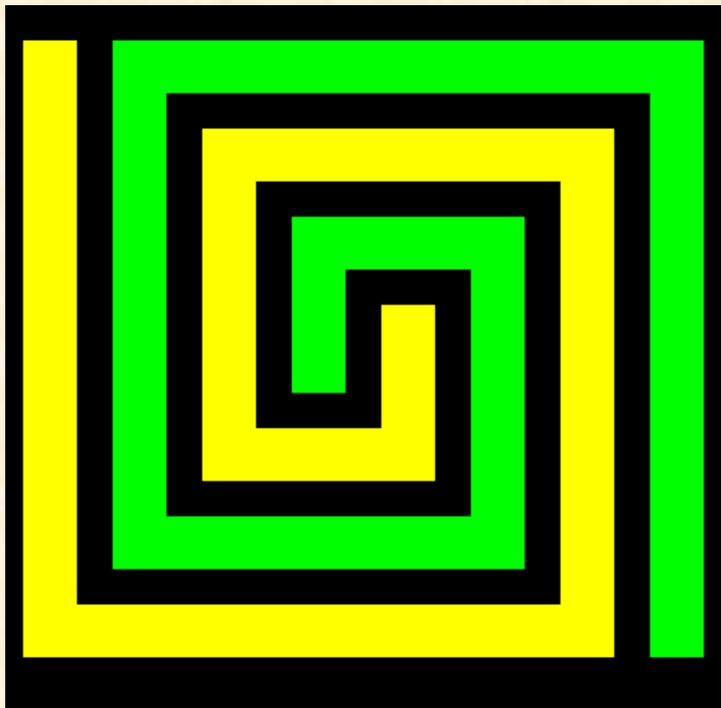


(a) Imagem artificial com baixo contraste; (b) Comportamento dos osciladores, $\sigma=0,10$;
 (c) Crescimento de fase, $\sigma=0,10$.

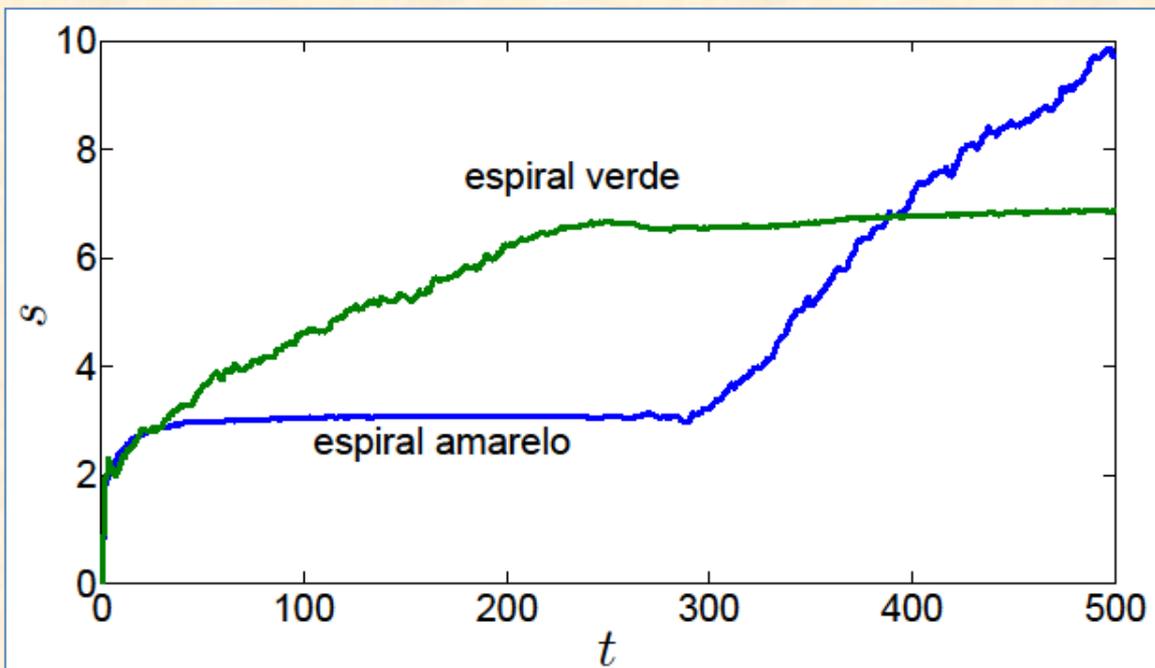
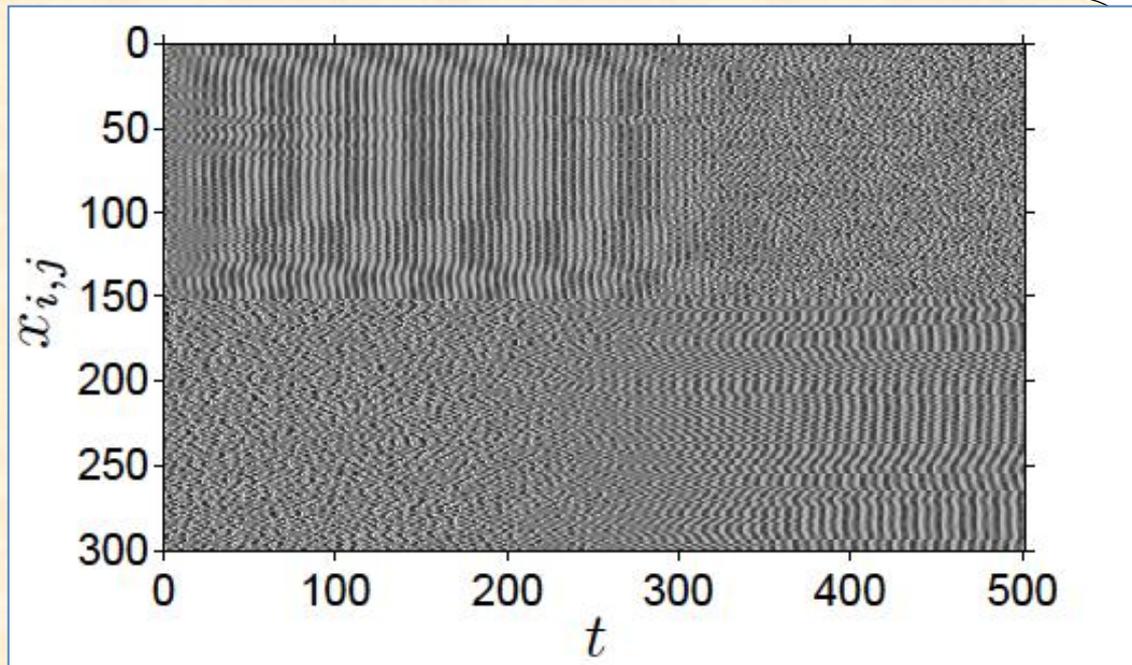


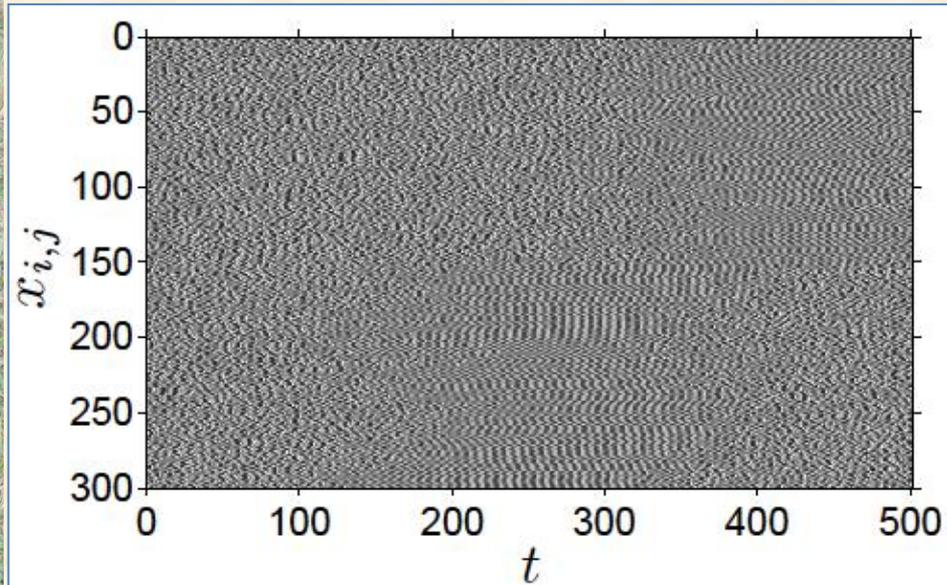
Atenção visual com imagem real - "Flor Gloxínia": (a) Imagem fonte; (b) Comportamento dos osciladores; (c) Crescimento de fase; (d) Séries temporais do desvio padrão de fase de cada objeto.

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.

