

- 
- 
- 
- 
- 

# IF-705 – Automação Inteligente

## Mapas Auto-Organizáveis

Aluizio Fausto Ribeiro Araújo  
Universidade Federal de Pernambuco  
Centro de Informática - CIn  
Departamento de Sistemas da Computação  
[aluizioa@cin.ufpe.br](mailto:aluizioa@cin.ufpe.br)



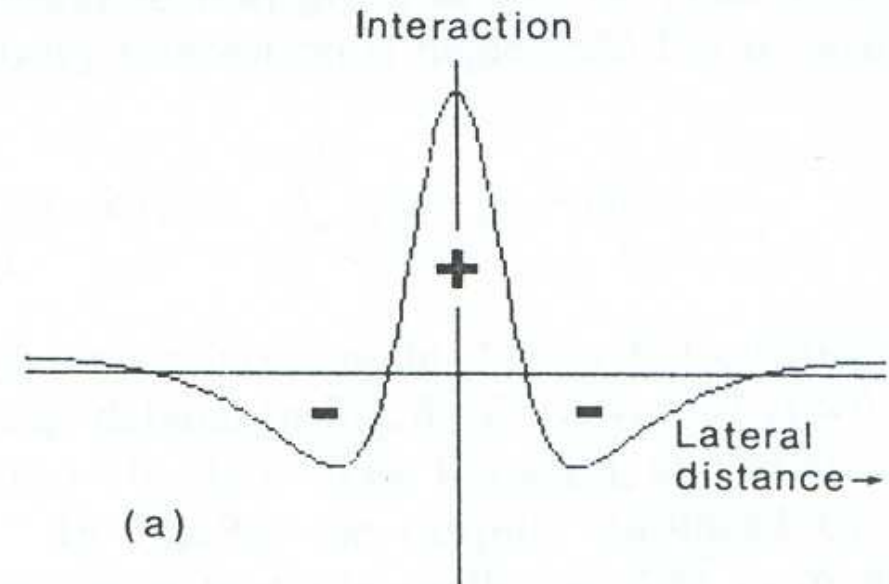
- 
- 
- 
- 
-

# Conteúdo

- Introdução
- Mapas Auto-organizáveis (SOM)
- SOM: Estrutura e Processamento
- Ilustração do SOM
- Limitações do SOM

# Introdução

- Inspiração neurofisiológica:
  - Um neurônio ativado que dispara um pulso causa a excitação de outros neurônios que distam dele entre 50 e 100  $\mu m$ .
  - A propagação da excitação para áreas não relacionadas com o processo excitatório é impedida por inibição de região em torno da excitada.



# Introdução

- A localização espacial de uma unidade de saída em um mapa topográfico corresponde para um domínio ou característica particular dos dados extraídas do espaço de entrada. (Kohonen 1990).
- Willshaw e von der Malsburg discutem a fundamentação neurobiológica.
- Kohonen trata mais do procedimento (modelagem para computadores) que pode realizar redução de dados.

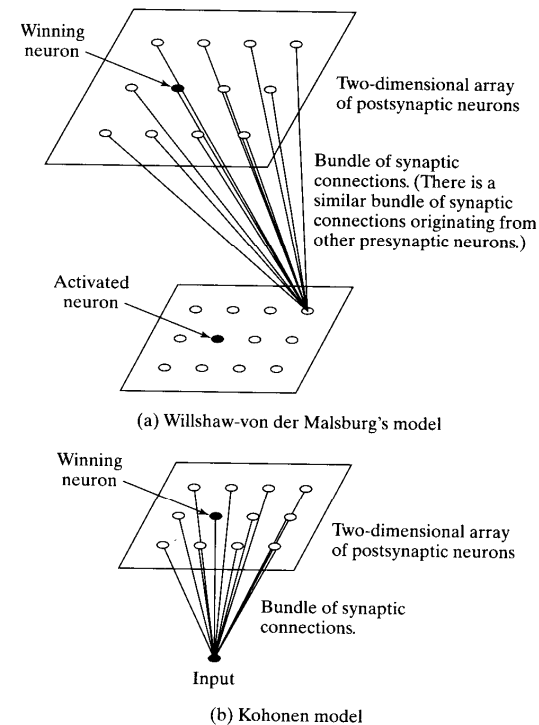


FIGURE 9.1 Two self-organized feature maps.

# Mapas Auto-organizáveis (SOM)

- Um Mapa Auto-organizável visa transformar um sinal de entrada de dimensão arbitrária em um mapa discreto de uma ou duas dimensões. Esta transformação é realizada adaptativamente de modo a conservar a ordenação topológica.
- Algumas características de SOM decorrem da observação de neurônios operando no cérebro:
  - O disparo de um neurônio influencia disparos de neurônios próximos.
  - Neurônios distantes entre si parecem se inibir mutuamente.
  - Neurônios parecem ter tarefas não redundantes.


# Mapas Auto-organizáveis (SOM)

- Kohonen (1982) propôs SOM que
  - Mapeia espaços de sinais de altas dimensões em estruturas topológicas de dimensões mais baixas.
  - Preserva vizinhanças de sinais.
  - Representa regiões de alta densidade de sinais por regiões de alta densidade de nodos.
  - Provê similaridade explícita entre diferentes agrupamentos.
- Áreas de aplicação:
  - Reconhecimento de discurso (Kohonen, 1988)
  - Compressão de dados (Schweizer et al., 1991)
  - Otimização combinatória (Favat & Walker, 1991)

# Mapas Auto-organizáveis (SOM)


- Estrutura Básica

- Uma camada de entrada e outra de saída.
- O mapa resultante é codificado na camada de saída.
- A topologia da camada de saída é frequentemente um gradil bidimensional de nodos.
- Cada nó de entrada é conectado com todos nós de saída.
- Cada nó de saída é conectado com vizinhos.



# Mapas Auto-organizáveis (SOM)

- Processamento:
  - Apresenta-se uma excitação (vetor de características) nos nodos de entrada.
  - Encontre o vencedor entre os vetores de pesos associados a cada unidade de processamento da camada de saída.
  - Atualize o vetor de pesos da unidade vencedora e de seus vizinhos com taxas de aprendizagem distintas.







# Mapas Auto-organizáveis (SOM)

– Aprendizagem inclui três tipos de operações:

- Competição
- Adaptação
- Colaboração




Coordenadas da amostra  $\xi$

# Mapas Auto-organizáveis (SOM)

– Aprendizagem inclui três tipos de operações:

- Competição
- Adaptação
- Cooperação



# Mapas Auto-organizáveis (SOM)


- **Competição:**

- Dado um vetor de entrada  $\mathbf{x} = [x_1, x_2, \dots, x_m]^T$
- Considere os vetores de pesos:  $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T$ , onde  $j = 1, 2, \dots, N_{un}$  (número total de unidades de processamento na camada de saída).
- Selecione a unidade com o maior valor para  $\mathbf{w}_v^T \mathbf{x}$ , isto é,  $v(\mathbf{x}) = \arg \min_j \|\mathbf{x} - \mathbf{w}_j\|$ .
- Um espaço contínuo de padrões de entrada é mapeado para um espaço de saída discreto por este processo de competição entre as unidades de processamento na camada de saída.

# Mapas Auto-organizáveis (SOM)

– Aprendizagem inclui três tipos de operações:

- Competição
- Adaptação
- Cooperação




# Mapas Auto-organizáveis (SOM)

- **Adaptação:**

- Etapa que compreende a modificação dos pesos sinápticos da unidade vencedora por uma regra de aprendizagem Hebbiana:  
$$\mathbf{w}_v(n+1) = \mathbf{w}_v(n) + \eta(n) h_{j,v(\mathbf{x})}(n)[\mathbf{x} - \mathbf{w}_j(n)].$$
- O vetor de pesos sinápticos da unidade vencedora,  $\mathbf{w}_v$ , se move na direção do vetor de entrada  $\mathbf{x}$ . Com a repetição de apresentações dos dados de treinamento, cada um dos vetores de pesos sinápticos tende a reproduzir a distribuição do espaço de entrada devido à atualização da vizinhança que leva ao ordenamento topológico.
- A taxa de aprendizagem,  $\eta(n)$ , deve variar no tempo para que ajustes iniciais grandes se transformem em ajustes pequenos mais tarde:  $\eta(n) = \eta_0 \exp(-n/\tau_2)$ ,  $n = 0, 1, 2, \dots$

# Mapas Auto-organizáveis (SOM)

- Aprendizagem inclui três tipos de operações:
  - Competição
  - Adaptação
  - **Cooperação**



# Mapas Auto-organizáveis (SOM)

## • Cooperação

- Envolve a determinação de uma vizinhança topológica que seja "neurologicamente correta".
- Seja  $h_{j,v(\mathbf{x})}(n)$  a vizinhança topológica centrada no vencedor,  $v$ , e relativa a um grupo de unidades denotadas por  $j$ .
- A vizinhança topológica é simétrica com respeito ao ponto de máximo e a sua amplitude decresce monotonicamente com o crescimento da distância lateral, por exemplo,  $h_{j,v(\mathbf{x})}(n) = \exp(-d_{j,v}^2/2\sigma^2(n))$ .  
para  $\sigma(n) = \sigma_0 \exp(-n/\tau_1)$ ,  $n = 0, 1, 2, \dots$




FIGURE 9.3 Gaussian neighborhood function.

# Mapas Auto-organizáveis (SOM)

- **Ordenamento**

- Tipicamente, a fase de auto-organização ou ordenamento leva, no máximo, 1000 iterações.
- Valores para os parâmetros:  $\eta(n) = [0.1, 0.01]$ ,  $\tau_2 = 1000$ .
- A função  $h_{j,v}(n)$  expressa um raio, a partir do vencedor, com respeito a um conjunto de unidades, os vizinhos, onde  
 $\tau_1 = 1000 / \log \sigma_0$ .

- **Convergência**

- A fase de convergência envolve a sintonia fina do mapa e usualmente leva 500 vezes o número de unidades de saída da rede.
- Pode-se empregar  $\eta(n) = 0.01$ , e a vizinhança,  $h_{j,v}(n)$ , passa a ter tamanho de uma ou nenhuma unidade vizinha.



# Exemplo de SOM


- **Dados de entrada**

- Um conjunto de vetores tri-dimensionais de valores RGB para descrever cores.

|     |     |     |                |
|-----|-----|-----|----------------|
| 250 | 235 | 215 | antique white  |
| 165 | 042 | 042 | brown          |
| 222 | 184 | 135 | burlywood      |
| 210 | 105 | 30  | chocolate      |
| 255 | 127 | 80  | coral          |
| 184 | 134 | 11  | dark goldenrod |
| 189 | 183 | 107 | dark khaki     |
| 255 | 140 |     | dark orange    |
| 233 | 150 | 122 | dark salmon    |
| ... | ... | ... | ...            |


# Exemplo de SOM

- **Encontre o vencedor e seu vizinhos:**




# Exemplo de SOM

- **Atualize o vetor de pesos do vencedor e de seus vizinhos:**
  - O vetor de pesos do vencedor e de seus vizinhos se aproxima do vetor de entrada.



# Exemplo de SOM

- **Resultados:**
  - Exemplo de 100 primeiros passos de um processo de ordenamento no qual cada círculo corresponde a um nodo com o ângulo de seu vetor de pesos.




# Exemplo de SOM


- **Resultados:**

- Exemplo de 1000 primeiros passos de um processo de ordenamento no qual cada círculo corresponde a um nodo com o ângulo de seu vetor de pesos.

1000

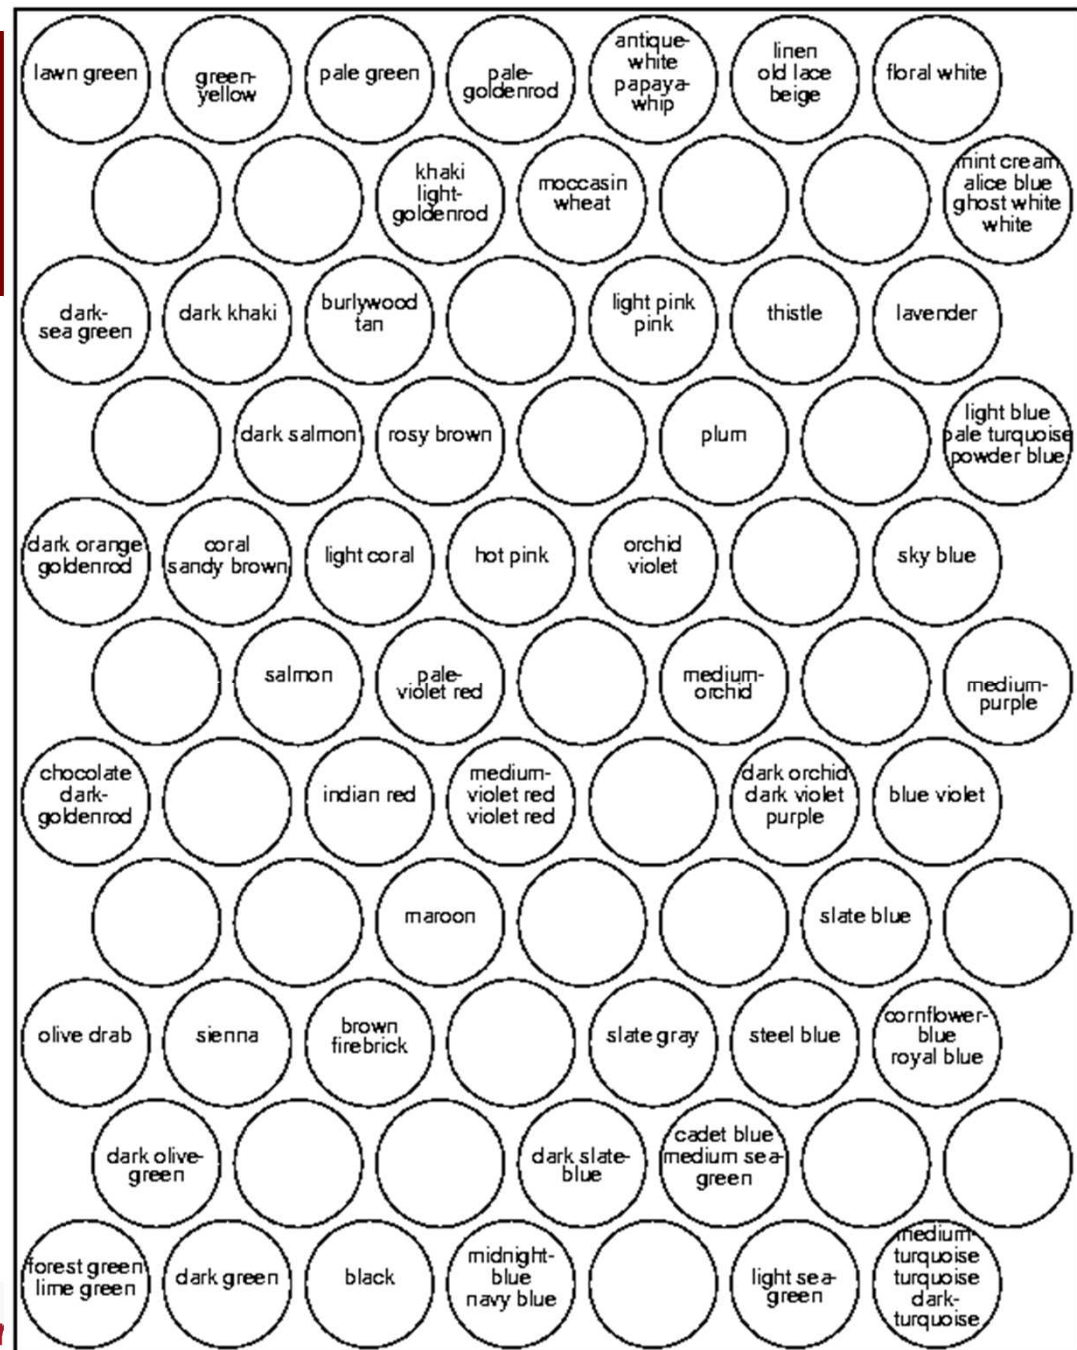


10000



# Exemplo de SOM

- **Mapa de cores:**
  - Mapa gerado pelo SOM a partir dos valores RGB de entrada.
  - A BMU é rotulada de acordo com o que a rede encontrou e o rótulo é o nome das cores.
  - Existência de unidades mortas.



# Mapas Auto-organizáveis (SOM)

- Limitações:
  - A pré-definição da estrutura limita o mapeamento resultantes.
    - Número fixo de nodos.
    - Conexões entre nodos pré-definidas.