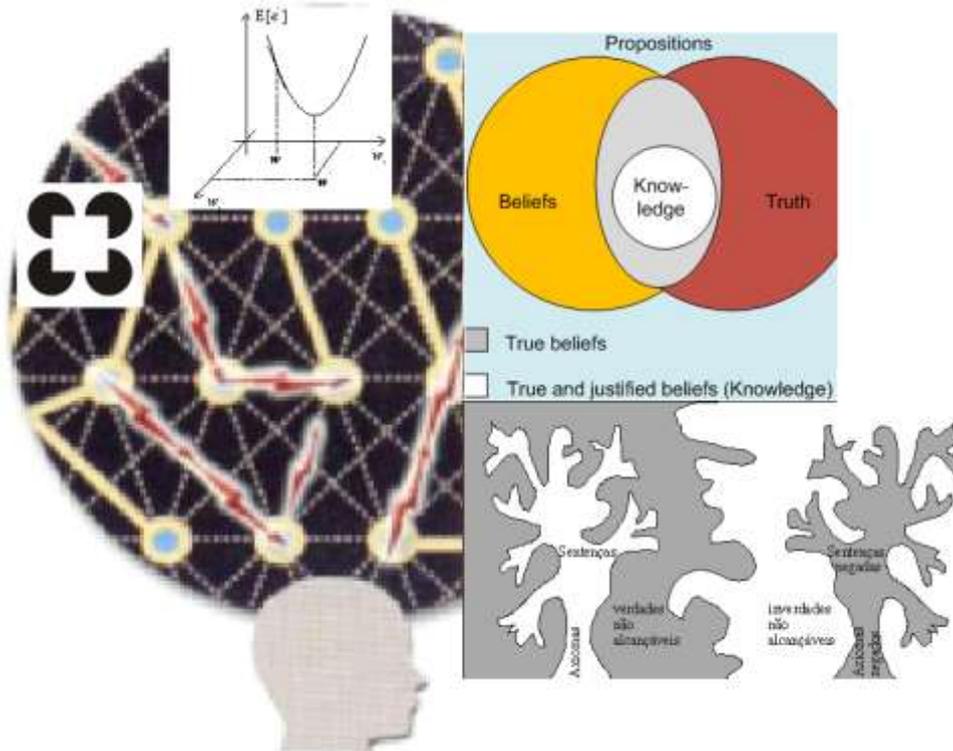




Nome: _____ Matrícula: _____

**- RESOLUÇÃO –
1ª PROVA ICIN
2º/2012**



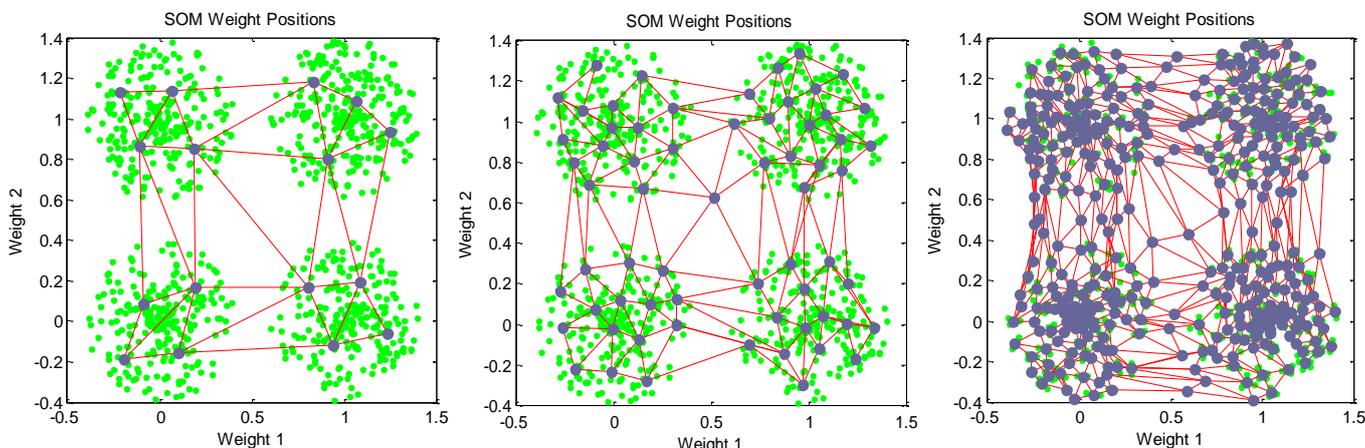
Questão 1 (3,0) As seguintes sentenças são Verdadeiras ou Falsas? Justifique cada resposta. (Se alguma parte da sentença é falsa, considere a sentença falsa. É necessário indicar todas as partes falsas).

- (0,5) O quadrado de Kanizsa, 1976, ilustra uma característica do ser humano que pode ser facilmente implementada em computadores digitais (passos lógicos e aritméticos). O ser humano consegue “ver a floresta além das árvores”, isto é, os pixels não são vistos individualmente, mas considerando padrões previamente armazenados.
- (0,5) Na matemática, um axioma é uma hipótese inicial da qual outros enunciados são logicamente derivados. Pode ser uma sentença, uma proposição, um enunciado ou uma regra que permite a construção de um sistema formal. Na engenharia, axiomas são, em geral, aceitos sem provas formais e suas escolhas são negociadas a partir do ponto de vista utilitário e econômico. Podem também ser considerados como hipóteses na modelagem e mudados depois da validação do modelo.
- (0,5) Uma ADALINE (*ADaptive LINear Element*) adapta cautelosamente os pesos da rede procurando o mínimo do erro quadrático médio. Uma aplicação interessante desta rede de uma camada é a identificação recursiva FIR de sistemas dinâmicos lineares invariantes no tempo. De acordo com as condições iniciais diferentes respostas são obtidas ao longo do tempo.
- (0,5) “Em uma sala com 23 pessoas, a chance de que pelo menos duas tenham a mesma data de aniversário é maior que 50%”. Esta afirmação é um paradoxo, pois o senso comum contraria o resultado estatístico.
- (0,5) Verdades não alcançáveis, que não partem de um conjunto de axiomas, podem ser “encontradas” por métodos heurísticos. Paradigmas diferentes, como RNAs e Algoritmos Genéticos podem eventualmente, fornecer diferentes soluções para um mesmo problema.
- (0,5) Redes Neurais com várias camadas são sempre melhores que uma camada única.

- F – não é fácil reconhecer padrões utilizando computadores digitais, habilidade adquirida pelos seres “inteligentes”.
- V
- V
- V
- V
- F – Redes Adaline só tem 1 camada (várias camadas são redundantes e sempre existe equivalência de 1 camada).

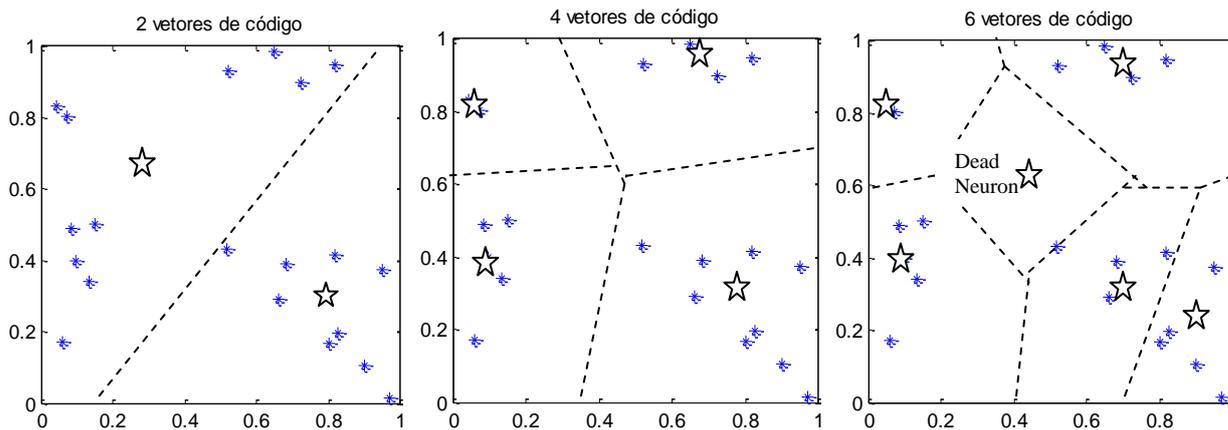
Questão 2: (4,0): Considerando três diferentes redes neurais artificiais que visam “descobrir” a distribuição estatística dos dados de entrada, responda sucintamente:

a) (1,0) Redes **SOM** (Self Organizing Maps) tem treinamento não supervisionado considerando relação de vizinhança. Qual dos três mapas representa “melhor” os dados de treinamento? Por quê?



 O “melhor” treinamento é aquele que abrange melhor a distribuição dos dados de treinamento.
 - A primeira opção tem muito poucos neurônios e assim cobre esparsamente a distribuição de pontos de treinamento.
 - A terceira opção tem neurônios de mais e assim sobram neurônios (devido à relação de vizinhança) em regiões onde não pontos de treinamento.
 - A **segunda rede SOM** é a melhor, onde a distribuição das “nuvens circulares” dos pontos de treinamento é bem caracterizada. O neurônio que “sobra” entre os agrupamentos é um mal menor causado pela relação de vizinhança da SOM.

b) (1.5) **Camadas Competitivas** podem ser utilizadas para criar vetores de código. Compressão de dados é uma aplicação típica. Códigos menores são, por exemplo, atribuídos a dados mais frequentes. Na figura abaixo temos 20 dados de entrada (*). De acordo com o número de vetores de código, indique posições prováveis dos vetores de código após o treinamento. Em cada caso mostre as regiões no espaço de entrada que são associadas aos vetores de código.



 Em uma camada competitiva a classificação é feita pelo neurônio vencedor (menor distância euclidiana). Desta forma a fronteira entre dois neurônios é dada por uma reta perpendicular à reta que une os dois neurônios, passando pelo ponto médio. Isto vale até que outro neurônio passe a definir uma nova fronteira (diagrama de Voronoi).
 2 - com dois neurônios uma possibilidade é que um neurônio seja atraído pela maior densidade de pontos (à direita, em baixo) e o outro neurônio fique numa posição intermediária entre as outras 3 nuvens (uma constituída de apenas dois pontos).
 4 – com 4 neurônios é possível que cada nuvem seja representada por um neurônio.
 6 – com 6 neurônios existe a possibilidade de que a nuvem maior acomode 2 neuronios. É provável que sobre um neurônio “morto”, que nunca foi o vencedor nesta configuração de dados de treinamento. Isto ocorre quando todos os dados de treinamento já tem um neurônio mais próximo que o neurônio morto.

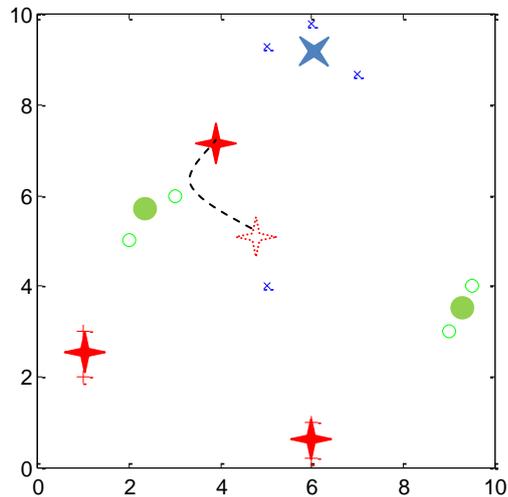
- c) (1,5) **LVQ1** compara-se o vetor de entrada X com os vetores de código W_j . O neurônio c , cujo vetor de código W_c é mais semelhante a X é dito o neurônio vencedor. $\|X - W_c\| = \min_j (\|X - W_j\|)$

$$W_c(t+1) = W_c(t) + \alpha(t)[X(t) - W_c(t)] \quad \text{se classe}(W_c) = \text{classe}(X)$$

$$W_c(t+1) = W_c(t) - \alpha(t)[X(t) - W_c(t)] \quad \text{se classe}(W_c) \neq \text{classe}(X)$$

$$W_j(t+1) = W_j(t) \quad \text{para todo } j \neq c; \quad 0 < \alpha(t) < 1, \text{ taxa de aprendizagem, usualmente } \alpha(0) = 0,1 \text{ e decai linearmente.}$$

Para cada classe há quatro padrões de entrada. Considere (1, 2 e 3) vetores de código associados às classes (x,o,+). Ao iniciar os vetores de código estão todos nas coordenadas (5,5). Apresente, via “simulação virtual” do algoritmo LVQ1, uma distribuição plausível dos vetores de código.



-
- Cada neurônio é atraído pelos pontos de treinamento associados à sua classe.
 - O terceiro neurônio + está “sobrando” e será primeiro repellido pelo dado azul x e depois pelo dado verde o até que ocupe uma posição onde nunca mais será vencedor.
 - O ponto de treinamento azul x em (5,4), uma vez selecionado terá como neurônio vencedor o ponto verde o à esquerda deste. A consequente repulsão faz com que o neurônio verde não fique exatamente entre os pontos de treinamento verdes.

3ª Questão (3,0) Uma memória associativa de Hopfield deve armazenar os seguintes padrões binários:

A_1	A_2	A_3	<i>sequência de bits</i>																																				
<table border="1" style="display: inline-table; border-collapse: collapse;"><tr><td>1</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	0	1	1	0	1	1	0	1	<table border="1" style="display: inline-table; border-collapse: collapse;"><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td></tr><tr><td>0</td><td>1</td><td>0</td></tr></table>	0	1	0	1	1	0	0	1	0	<table border="1" style="display: inline-table; border-collapse: collapse;"><tr><td>1</td><td>1</td><td>0</td></tr><tr><td>0</td><td>0</td><td>1</td></tr><tr><td>0</td><td>0</td><td>0</td></tr></table>	1	1	0	0	0	1	0	0	0	<table border="1" style="display: inline-table; border-collapse: collapse;"><tr><td>1</td><td>2</td><td>3</td></tr><tr><td>4</td><td>5</td><td>6</td></tr><tr><td>7</td><td>8</td><td>9</td></tr></table>	1	2	3	4	5	6	7	8	9
1	0	1																																					
1	0	1																																					
1	0	1																																					
0	1	0																																					
1	1	0																																					
0	1	0																																					
1	1	0																																					
0	0	1																																					
0	0	0																																					
1	2	3																																					
4	5	6																																					
7	8	9																																					

Cada padrão binário é dado por: $A_p = [a_1^p \ a_i^p \ \dots \ a_9^p]$, com $a_i^p = 0$ ou 1 , $i=1:9$, $p=1:3$. Considere o limiar de disparo dos neurônios $L_j = 0$. A equação de treinamento da rede de Hopfield binária é: $w_{ij} = \sum_{p=1}^m (2a_i^p - 1)(2a_j^p - 1)$

a) (1,0) Obtenha a matriz de pesos correspondente à rede de Hopfield.

b) (1,5) Considerando a operação sequencial da rede de Hopfield, calcule o padrão que a rede fornece após a 1ª época e após a sua estabilização, para o seguinte padrão inicial:

0	1	1
1	1	0
1	0	0

c) (0,5) Para a implementação binária da rede de Hopfield a matriz de pesos é uma função única dos dados de treinamento. Comente pelo menos dois aspectos que restringem a aplicação da rede de Hopfield para problemas “práticos”.

$$W = \begin{bmatrix} 0 & -1 & 1 & -1 & -3 & 3 & 1 & -3 & 1 \\ -1 & 0 & -3 & -1 & 1 & -1 & -3 & 1 & -3 \\ 1 & -3 & 0 & 1 & -1 & 1 & 3 & -1 & 3 \\ -1 & -1 & 1 & 0 & 1 & -1 & 1 & 1 & 1 \\ -3 & 1 & -1 & 1 & 0 & -3 & -1 & 3 & -1 \\ 3 & -1 & 1 & -1 & -3 & 0 & 1 & -3 & 1 \\ 1 & -3 & 3 & 1 & -1 & 1 & 0 & -1 & 3 \\ -3 & 1 & -1 & 1 & 3 & -3 & -1 & 0 & -1 \\ 1 & -3 & 3 & 1 & -1 & 1 & 3 & -1 & 0 \end{bmatrix}$$

Primeira época:

0	0	1
1	0	1
1	0	1

Padrão final obtido (A_1):

1	0	1
1	0	1
1	0	1

EP disparado	Soma do EP	Saída do EP	Novo vetor de saída
1	-3	0	0 1 1 1 1 0 1 0 0
2	-6	0	0 0 1 1 1 0 1 0 0
3	3	1	0 0 1 1 1 0 1 0 0
4	3	1	0 0 1 1 1 0 1 0 0
5	-1	0	0 0 1 1 0 0 1 0 0
6	1	1	0 0 1 1 0 1 1 0 0
7	5	1	0 0 1 1 0 1 1 0 0
8	-4	0	0 0 1 1 0 1 1 0 0
9	8	1	0 0 1 1 0 1 1 0 1
1	5	1	1 0 1 1 0 1 1 0 1
2	-12	0	1 0 1 1 0 1 1 0 1
3	9	1	1 0 1 1 0 1 1 0 1
4	1	1	1 0 1 1 0 1 1 0 1
5	-8	0	1 0 1 1 0 1 1 0 1
6	5	1	1 0 1 1 0 1 1 0 1
7	9	1	1 0 1 1 0 1 1 0 1
8	-8	0	1 0 1 1 0 1 1 0 1
9	9	1	1 0 1 1 0 1 1 0 1
1	5	1	1 0 1 1 0 1 1 0 1
...

Após um ciclo completo (época) não houve alteração de estado → padrão final (A_1)