



MAC0425 Inteligência Artificial

Terceira Avaliação (P3)

NOME: **GABARITO**

NUSP: **04252019**

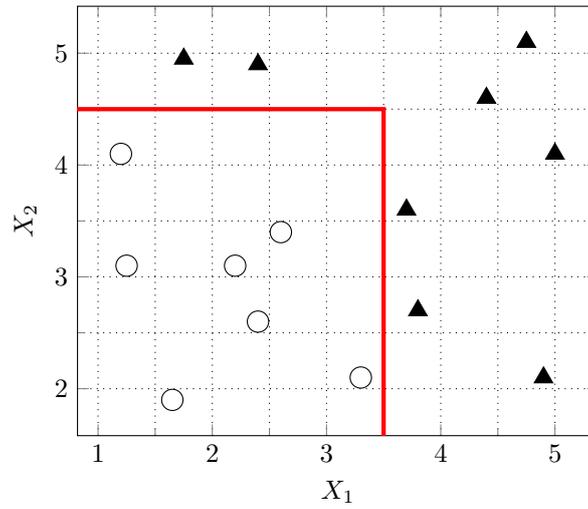
ASSINATURA:

INSTRUÇÕES:

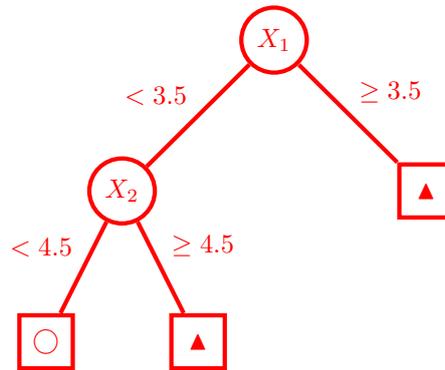
- Leia atentamente os enunciados.
 - Este exame é composto por questões dissertativas; todas as respostas devem ser justificadas.
 - Escreva suas resposta nos locais indicados, utilizando caneta esferográfica azul ou preta.
 - Use os versos das folhas como rascunho; escreva sua reespota apenas quando tiver certeza.
 - Você pode consultar apenas uma folha A4 (frente e verso) individual.
 - O uso de equipamentos eletrônicos (calculadoras, celulares, computadores) não é permitido.
 - **Duração:** 120 minutos.
-



Questão 2. Projete um classificador por árvore de decisão de 2 níveis que classifica corretamente o conjunto de dados abaixo. Desenhe a superfície de decisão do classificador na figura e descreva os parâmetros necessários.



A seguinte árvore de decisão classifica corretamente todos os pontos acima.



A superfície de decisão induzida pela árvore é desenhada em vermelho na figura.



Questão 3. O algoritmo de Q-Learning com aproximação linear considera que a função $Q(s, a)$ é uma combinação linear de pesos w_k e funções características $f_k(s, a)$, atualizada através da equação

$$w_k^{(i+1)} = w_k^{(i)} + \alpha [R(s, a) + \gamma \max_{a'} Q^*(s', a') - Q^{(i)}(s, a)] f_k(s, a),$$

onde α é a taxa de aprendizado, γ é o fator de desconto e $Q^*(s', a')$ é uma função oráculo que é considerada fixa (no algoritmo visto em classe usamos $Q^{(i)}(s', a')$ para estimar esse valor, mas para esse exercício considere esse valor como uma constante).

Obtenha uma função objetivo $J(w)$ para a qual a equação acima representa a atualização de um algoritmo de descida do gradiente estocástico.

O algoritmo de descida do gradiente estocástico otimiza os parâmetros w a fim de minimizar uma função $J(w)$ aplicando a regra

$$w_k^{(i+1)} \leftarrow w_k^{(i)} - \alpha \frac{\partial J_i(w)}{\partial w_k},$$

onde $J(w) = \sum_i J_i(w)$.

Já o algoritmo de Q-Learning com aproximação linear assume que

$$Q(s, a) = \sum_k w_k \cdot f_k(s, a).$$

Portanto procuramos uma função $J(w) = \sum_i J_i(w)$ tal que

$$\frac{\partial J_i(w)}{\partial w_k} = -[R(s, a) + \max_{a'} Q^*(s', a') - Q^{(i)}(s, a)] f_k(s, a).$$

A seguinte função satisfaz essa propriedade:

$$J(w) = \frac{1}{2} \sum_s \sum_a \sum_{s'} (R(s, a) + \gamma \max_{a'} Q^*(s', a') - Q(s, a))^2.$$

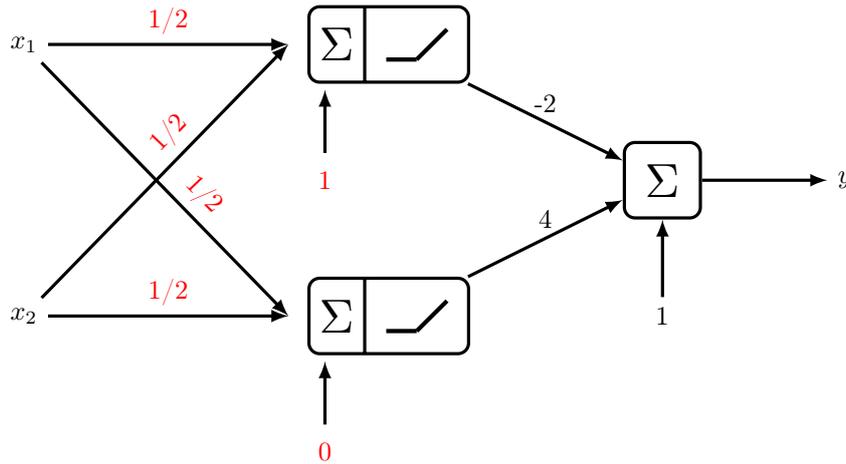
A cada iteração o algoritmo “seleciona” uma transição (s, a, s') e aplica a regra de atualização do enunciado.



Questão 4. Complete a especificação da rede neural abaixo para que ela compute a seguinte função:

x_1	x_2	y
-1	-1	1
-1	1	-1
1	-1	-1
1	1	1

Os neurônios da camada oculta possuem função de ativação ReLU ($\text{relu}(z) = \max(0, z)$); o neurônio da camada de saída é linear. Note que os valores dos pesos da camada de saída já estão especificados e não devem ser alterados.



Devido a especificação dos parâmetros da camada de saída, temos que

$$-2h_1 + 4h_2 + 1 = y, \quad h_1, h_2 \geq 0,$$

onde h_1 e h_2 são as saídas dos neurônios superior e inferior da camada oculta, respectivamente. Considerando os valores desejados para a função chegamos ao sistema de equações

$$\begin{aligned} h_1(-1, -1) &= 2h_2(-1, -1) & h_1(-1, 1) &= 2h_2(-1, 1) + 1 \\ h_1(1, -1) &= 2h_2(1, -1) + 1 & h_1(1, 1) &= 2h_2(1, 1) \end{aligned}$$

O sistema acima possui 8 incógnitas e 4 equações (e as condições de não-negatividade) e é portanto subdeterminado. Isso indica que o problema tem várias (infinitas, de fato) soluções possíveis. Uma forma de resolvê-lo é impor restrições adicionais as variáveis. Por exemplo, dada a característica do problema podemos assumir que h_1 e h_2 são funções simétricas em relação à bissetriz e portanto $h_1(-1, 1) = h_1(1, -1)$ e $h_2(-1, 1) = h_2(1, -1)$. Podemos também assumir que $h_1(-1, -1) = h_2(-1, -1) = 0$, e que $h_2(1, 1) = 1$ (outras suposições levam a respostas distintas). Essas restrições forçam h_1 e h_2 a serem funções crescentes de $x_1 + x_2$. Conseguimos dessa forma preencher, por tentativa e erro, a tabela abaixo com valores de h_1 e h_2 .

x_1	x_2	$x_1 + x_2$	z_1	h_1	z_2	h_2	y
-1	-1	-2	≤ 0	0	≤ 0	0	1
-1	1	0	1	1	≤ 0	0	-1
1	-1	0	1	1	≤ 0	0	-1
1	1	2	2	2	1	1	1

O valores z_1 and z_2 na tabela acima correspondem ao resultado da combinação linear dos neurônios da camada oculta (ou seja, antes de ser aplicada a função relu). Novamente por tentativa e erro, conseguimos chegar aos parâmetros da rede acima. Comparando as colunas de soma das entradas e dos das combinações lineares (z) conseguimos selecionar os pesos e limiares dos neurônios.