

IA353 – Redes Neurais (1s2020)

Exercícios Conceituais 1 – EC 1

Gabarito das questões que envolvem manipulação algébrica

Questão 2)

Obtenção da solução ótima para o problema de minimização:

$$\|A\mathbf{x} - \mathbf{b}\|_P^2 + \|\mathbf{x} - \mathbf{x}_0\|_Q^2$$

Resolução:

$$J(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|_P^2 + \|\mathbf{x} - \mathbf{x}_0\|_Q^2 = (A\mathbf{x} - \mathbf{b})^T P (A\mathbf{x} - \mathbf{b}) + (\mathbf{x} - \mathbf{x}_0)^T Q (\mathbf{x} - \mathbf{x}_0)$$

$$= (\mathbf{x}^T A^T - \mathbf{b}^T) (PA\mathbf{x} - P\mathbf{b}) + (\mathbf{x}^T - \mathbf{x}_0^T) (Q\mathbf{x} - Q\mathbf{x}_0)$$

$$= \mathbf{x}^T A^T PA\mathbf{x} - \mathbf{x}^T A^T P\mathbf{b} - \mathbf{b}^T PA\mathbf{x} + \mathbf{b}^T P\mathbf{b} + \mathbf{x}^T Q\mathbf{x} - \mathbf{x}^T Q\mathbf{x}_0 - \mathbf{x}_0^T Q\mathbf{x} + \mathbf{x}_0^T Q\mathbf{x}_0$$

$$\frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} = 2A^T PA\mathbf{x} - A^T P\mathbf{b} - A^T P\mathbf{b} + 2Q\mathbf{x} - Q\mathbf{x}_0 - Q\mathbf{x}_0 = 2A^T PA\mathbf{x} - 2A^T P\mathbf{b} + 2Q\mathbf{x} - 2Q\mathbf{x}_0$$

Aplicando a condição necessária de otimalidade, resulta:

$$\left. \frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}^*} = 0 \Rightarrow A^T PA\mathbf{x}^* - A^T P\mathbf{b} + Q\mathbf{x}^* - Q\mathbf{x}_0 = 0$$

$$(A^T PA + Q)\mathbf{x}^* = A^T P\mathbf{b} + Q\mathbf{x}_0$$

As matrizes P e Q são sabidas serem simétricas, mas não são de nosso conhecimento.

No entanto, a resposta desejada supõe a existência da inversa de $A^T PA + Q$, o que passaremos a considerar a partir daqui. Assim, multiplicando à esquerda por

$(A^T PA + Q)^{-1}$ nos dois lados da equação acima, obtém-se:

$$(A^T PA + Q)^{-1} (A^T PA + Q)\mathbf{x}^* = (A^T PA + Q)^{-1} (A^T P\mathbf{b} + Q\mathbf{x}_0)$$

$$\mathbf{x}^* = (A^T PA + Q)^{-1} (A^T P\mathbf{b} + Q\mathbf{x}_0).$$

O coeficiente de regularização é fixo e igual a 1 porque a matriz Q já o inclui. Isso pode ser constatado de duas formas alternativas:

- Considere um coeficiente de regularização diferente de 1:

$$\|A\mathbf{x} - \mathbf{b}\|_P^2 + \lambda \|\mathbf{x} - \mathbf{x}_0\|_Q^2$$

Essa nova formulação vai levar à solução:

$$\mathbf{x}^* = (A^T PA + \lambda Q)^{-1} (A^T P\mathbf{b} + \lambda Q\mathbf{x}_0)$$

Fazendo $Q' = \lambda Q$, retorna-se à formulação com coeficiente de regularização igual a 1:

$$\|A\mathbf{x} - \mathbf{b}\|_P^2 + \|\mathbf{x} - \mathbf{x}_0\|_{Q'}^2$$

- Tomando $P = I$, $Q = \lambda I$ e $\mathbf{x}_0 = 0$, obtém-se a formulação original que estávamos acostumados a tratar, o que indica que o coeficiente de regularização de fato está embutido na matriz Q :

$$\|\mathbf{Ax} - \mathbf{b}\|^2 + \lambda \|\mathbf{x}\|^2.$$

Questão 3)

- (a) Prove que matrizes $n \times n$ que podem ser decompostas na forma $M = N^T N$ com $N \in \mathfrak{R}^{m \times n}$, são matrizes simétricas e semi-definidas positivas.

Resolução:

$$M^T = (N^T N)^T = N^T (N^T)^T = N^T N = M. \text{ Logo, } M \text{ é uma matriz simétrica.}$$

Por definição, uma matriz M de dimensão $n \times n$ é semi-definida positiva se $\mathbf{x}^T M \mathbf{x} \geq 0, \forall \mathbf{x} \in \mathfrak{R}^n$. Usando a decomposição, resulta:

$$\mathbf{x}^T M \mathbf{x} = \mathbf{x}^T N^T N \mathbf{x} = (N \mathbf{x})^T (N \mathbf{x}) = \|N \mathbf{x}\|_2^2.$$

Por definição, a norma euclidiana é tal que $\|\mathbf{z}\|_2 \geq 0, \forall \mathbf{z} \in \mathfrak{R}^m$, ou seja:

$$\mathbf{x}^T M \mathbf{x} = \|N \mathbf{x}\|_2^2 \geq 0, \forall \mathbf{x} \in \mathfrak{R}^n,$$

demonstrando assim que M é semi-definida positiva.

- (b) Supondo $m > n$ e tomando N de posto completo, prove que M tem que ser definida positiva.

Por definição, uma matriz M de dimensão $n \times n$ é definida positiva se $\mathbf{x}^T M \mathbf{x} > 0, \forall \mathbf{x} \in \mathfrak{R}_+^n$, onde \mathfrak{R}_+^n representa o espaço \mathfrak{R}^n sem o vetor nulo. Se a matriz N tem posto completo, então o seu espaço nulo tem dimensão zero, o que indica que somente o vetor nulo é solução de $N \mathbf{x} = 0$. Você pode recorrer também à definição de independência linear entre vetores e aplicar a $N \mathbf{x} = 0$, onde $N \mathbf{x}$ nada mais é que uma combinação linear das colunas de N . Logo:

$$\mathbf{x}^T M \mathbf{x} = \|N \mathbf{x}\|_2^2 > 0, \forall \mathbf{x} \in \mathfrak{R}_+^n,$$

demonstrando assim que M é definida positiva.

- (c) Usando o conceito de matriz ortogonal, prove que N pode não ser única, para um mesmo M .

Resolução:

Por definição, uma matriz ortogonal Q é tal que $Q^T Q = I$, ou seja, $Q^T = Q^{-1}$. Sendo assim, tomando uma matriz Q ortogonal qualquer e de dimensão apropriada, sabe-se que $QN \neq N$. No entanto, se fizermos:

$(QN)^T(QN) = N^T Q^T QN = N^T IN = N^T N = M$. Logo, existe uma matriz diferente de N que produz M .

(d) Apresente uma proposta para obter N , dada uma matriz M definida positiva.

Resolução:

Sendo M uma matriz simétrica, é sempre possível obter n autovetores ortogonais para M , que irão compor as colunas de uma matriz T . Com essa matriz T , é possível chegar a uma matriz diagonal Λ que tenha os autovalores de M em sua diagonal, na forma:

$$M = T\Lambda T^T.$$

Como M é definida positiva, seus autovalores são todos positivos. Sendo assim, é possível obter uma matriz diagonal Λ_1 tal que os elementos da diagonal são a raiz quadrada dos autovalores de M . Sendo assim, obtém-se:

$$M = T\Lambda T^T = T\Lambda_1\Lambda_1 T^T = T\Lambda_1^T\Lambda_1 T^T = (\Lambda_1 T^T)^T (\Lambda_1 T^T).$$

Agora é só fazer $N = \Lambda_1 T^T$, mostrando que é possível obter N a partir da decomposição espectral de M .

Uma alternativa para resolver esta questão seria recorrer à Fatoração de Cholesky (https://en.wikipedia.org/wiki/Cholesky_decomposition), mas aí teria que mostrar como fica a matriz N .

Questão 4)

Resolução:

Temos que lembrar que a linearização é sempre realizada em algum ponto específico, da mesma forma que o vetor gradiente (para o treinamento supervisionado de redes neurais) sempre é obtido em um ponto específico da superfície de erro. Com isso, a obtenção de $f_L(x, y)$, que é a versão linear de $f(x, y) = x\sqrt{y}$, requer expandir $f(x, y)$ em série de Taylor até primeira ordem, em torno de um determinado ponto (x_0, y_0) . Procedendo dessa forma, no entorno de (x_0, y_0) , resulta:

$$\begin{aligned} f(x, y) &\cong f_L(x, y) = f(x_0, y_0) + \left[\frac{\partial f(x, y)}{\partial x} \quad \frac{\partial f(x, y)}{\partial y} \right]_{(x,y)=(x_0,y_0)} \begin{bmatrix} x - x_0 \\ y - y_0 \end{bmatrix} \\ &= x_0\sqrt{y_0} + \left[\sqrt{y_0} \quad \frac{x}{2\sqrt{y_0}} \right]_{(x,y)=(x_0,y_0)} \begin{bmatrix} x - x_0 \\ y - y_0 \end{bmatrix} \\ &= x_0\sqrt{y_0} + \sqrt{y_0}(x - x_0) + \frac{x_0}{2\sqrt{y_0}}(y - y_0) \\ &= \sqrt{y_0}x + \frac{x_0}{2\sqrt{y_0}}y - \frac{x_0 y_0}{2\sqrt{y_0}} \end{aligned}$$

Logo:

$$f_L(x, y) = 2x + py - 8 = \sqrt{y_0}x + \frac{x_0}{2\sqrt{y_0}}y - \frac{x_0 y_0}{2\sqrt{y_0}},$$

o que conduz a:

$$\sqrt{y_0} = 2 \Rightarrow y_0 = 4$$

$$-\frac{x_0 y_0}{2\sqrt{y_0}} = -8 \Rightarrow x_0 = 8$$

$$\frac{x_0}{2\sqrt{y_0}} = p \Rightarrow p = 2$$

Cabe lembrar que é sempre possível conferir se o resultado está correto, ao comparar $f(x, y)$ com $f_L(x, y)$ no ponto (x_0, y_0) .