



APRENDIZADO DE MÁQUINA

PROF. RONALDO CRISTIANO PRATI

RONALDO.PRATI@UFABC.EDU.BR


BLOCO A, SALA 513-2

CLASSIFICAÇÃO

- Um outro problema dentro de aprendizado supervisionado é a **classificação**
 - y é discreto:
 - e-mail: SPAM/não SPAM?
 - transções online: fraudulenta/normal?
 - tumor: maligno/benigno?
- vamos começar com um problema de **classificação binária** (veremos multiclasse depois)

CLASSIFICAÇÃO

- Podemos usar regressão linear?
- y pode ser representado como 0 ou 1:
 - 0: classe negativa
 - 1: classe positiva
 - Um ponto de corte no valor predito (p.ex. acima de 0.5), é classificado como classe positiva



CLASSIFICAÇÃO

- E se tivermos poucos exemplos da classe 1?
Provavelmente a inclinação da reta seria menor, e classificaríamos tudo com classe 0.
- Nossa hipótese também prediz valores abaixo de 0 e acima de 1, apesar da classe só poder assumir os valores 0 e 1.
- **Regressão logística** pode contornar esses problemas

REGRESSÃO LOGÍSTICA


- Apesar de se chamar regressão, é um algoritmo de classificação
- A hipótese tem a forma de $h_{\theta}(x) = g(\theta^T x)$, em que:

$$g(z) = \frac{1}{1 + e^{-z}}$$

- Essa é a **função sigmoide** ou **função logística**
- Podemos reescrever $h_{\theta}(x)$ como

$$h_{\theta}(z) = \frac{1}{1 + e^{-\theta^T x}}$$

REGRESSÃO LOGÍSTICA



INTERPRETANDO A SAÍDA


- A hipótese $h_{\theta}(x)$ dá como saída um número entre 0 e 1 que pode ser interpretada como a probabilidade que $y = 1$ para a entrada x
 - Por exemplo, se $h_{\theta}(x) = 0.7$ para um certo x^i , o modelo dá 70% de chance de um tumor maligno
- Em outras palavras, $h_{\theta}(x) = P(y = 1|x, \theta)$
- Como o problema é binário, temos que:
$$P(y = 1|x, \theta) + P(y = 0|x, \theta) = 1$$
$$P(y = 0|x, \theta) = 1 - P(y = 1|x, \theta)$$

FRONTEIRA DE DECISÃO

- Para prever a classe, utilizamos aquela com maior probabilidade, segundo o modelo
 - Isso é equivalente a prever a classe 1 se $h_{\theta}(x) > 0.5$, e a classe 0 caso contrário
- Observando a função logística, temos que $h_{\theta}(x) = 0.5$ quando $z = 0$.
- Como $z = \theta^T x$, a linha $\theta^T x = 0$ é a fronteira de decisão entre as duas classes
 - $\theta^T x > 0$: prever classe 1
 - $\theta^T x \leq 0$: prever classe 0


FRONTEIRA DE DECISÃO

- A linha em que $h_{\theta}(x) = 0.5$ (ou que $\theta^T x = 0$) é a fronteira de decisão.



FRONTEIRA DE DECISÃO NÃO LINEAR

- Se adicionarmos novos atributos que fazem uma transformação não linear nos dados (como na aula passada, em que fizemos regressão polinomial adicionando atributos do tipo x^k)
- Por exemplo, se adicionarmos atributos quadráticos, podemos ter fronteiras de decisão do tipo



FUNÇÃO DE CUSTO PARA REGRESSÃO LOGÍSTICA

- Nossa hipótese é

$$h_{\theta}(z) = \frac{1}{1 + e^{-\theta^T x}}$$

- Na regressão linear temos que

$$J(\theta) = \frac{1}{m} \sum_i^m Cost(h_{\theta}(x), y)$$

Em que o custo é definido como:

$$Cost(h_{\theta}(x), y) = \frac{1}{2} (h_{\theta}(x) - y)^2$$

FUNÇÃO DE CUSTO PARA REGRESSÃO LOGÍSTICA



- Podemos usar a mesma função de custo para regressão logística?
 - Essa função de custo é não convexa (a função da nossa hipótese (sigmoid) é não linear)
 - Ao tentar minimizar, podemos ter muitos mínimos locais
 - O algoritmo da descida do gradiente pode não encontrar os melhores valores para θ
 - Temos uma função convexa para por no lugar?

FUNÇÃO DE CUSTO PARA REGRESSÃO LOGÍSTICA

- Uma função de custo convexa:

$$Cost(h_{\theta}(x), y) = \begin{cases} -\log(h_{\theta}(x)) & sey = 1 \\ -\log(1 - h_{\theta}(x)) & sey = 0 \end{cases}$$

FUNÇÃO DE CUSTO PARA REGRESSÃO LOGÍSTICA



FUNÇÃO DE CUSTO PARA REGRESSÃO LOGÍSTICA

- Como só temos duas classes, podemos escrever a função de custo de uma maneira mais compacta:

$$Cost(h_{\theta}(x), y) = -y \log(h_{\theta}(x)) - (1 - y) \log(1 - h_{\theta}(x))$$

- Essa função pode ser derivada da estatística, usando o princípio da estimação da máxima verossimilhança
- Assume que existe uma distribuição Gaussiana dos atributos
- É convexa

GRADIENTE DESCENDENTE PARA REGRESSÃO LOGÍSTICA

- Podemos usar o gradiente descendente para encontrar θ na regressão logística

$$\theta := \theta - \alpha \sum_i^m (h_{\theta}(x^i) - y^i) x^i$$

- Essa equação é a mesma da regressão linear
 - A única diferença é que agora usamos uma hipótese diferente
- Colocar os atributos na mesma escala também pode ser necessário

ALÉM DO GRADIENTE DESCENDENTE


- Existem outras possíveis maneiras de minimizar a função de custo
 - Gradiente conjugado
 - BFGS
 - L-BFGS
 - ...
- São algoritmos mais complexos e otimizados, que podem ser aplicados à mesma entrada e função de custo

ALÉM DO GRADIENTE DESCENDENTE

- Vantagens:
 - Não precisamos ajustar α (taxa de aprendizado) manualmente
 - Testam vários α internamente para escolher o mais adequado (além de outras melhorias)
 - Em geral, mais rápidos que o gradiente descendente
- Desvantagens
 - Difícil "acompanhamento"
 - Difícil implementação
 - Diferentes bibliotecas usam diferentes otimizações (desempenho diferente)

REGRESSÃO LOGÍSTICA MULTICLASSE

- Problemas multiclasse: mais de duas classes



REGRESSÃO LOGÍSTICA MULTICLASSE

- Estratégia "um contra todos" (*one-versus-all* ou *one-versus-rest*)
 - Dividir o conjunto de dados em diversos problemas de classificação (igual ao número de classes)
 - Em cada problema, uma das classes é a positiva, e as demais são agrupadas na negativa
 - Escolher a classe que maximiza $P(y = 1|x_k; \theta)$, em que k é a classe positiva no problema de classificação k

REGRESSÃO LOGÍSTICA MULTICLASSE

