

Aprendizagem Probabilística – Classificação Usando Naive Bayes

ESTAT0109 – Mineração de Dados em Estatística

Prof. Dr. Sadraque E. F. Lucena

sadraquelucena@academico.ufs.br

<http://sadraquelucena.github.io/mineracao>

Objetivo da Aula

- Compreender o funcionamento do algoritmo Naive Bayes.

Introdução

- O algoritmo Naive Bayes, também conhecido como Bayes ingênuo, faz parte da família dos *métodos bayesianos*.
- Ele utiliza dados de treino para calcular a probabilidade de um resultado pertencer a uma classe, com base nos dados de entrada.
- Classificadores bayesianos podem ser usados para:
 - Classificação de texto. Exemplo: detecção de e-mail de spam.
 - Segurança de Rede. Exemplo: detecção de intrusos em uma rede de computadores.
 - Diagnóstico médico. Exemplo: identificação de condições médicas com base em sintomas observados.

Introdução

- Classificadores bayesianos são ideais para problemas que requerem a consideração simultânea de vários atributos.
 - Mesmo atributos com efeitos relativamente pequenos podem ter um impacto significativo quando combinados em um modelo bayesiano.

Base: Teorema de Bayes

Base: Teorema de Bayes

Terminologia:

- $P(C)$: probabilidade *a priori* (*prior probability*).
 - Conhecimento inicial sobre C .
 - Ou seja, conhecimento sobre a aparição de exemplos da classe C no problema.
- $P(C|A)$: probabilidade *a posteriori* (*posterior probability*).
 - Probabilidade da instância pertencer à classe C após consideração do atributo A .
- $P(A|C)$: verossimilhança (*likelihood*).
- $P(A)$: probabilidade marginal (*marginal likelihood*).
- O uso do teorema de Bayes permite então recalcular a probabilidade de uma instância pertencer a uma classe após a obtenção de novas evidências sobre essa instância.

Exemplo 10.1

Suponha que queremos calcular a probabilidade de um email ser classificado como *spam* quando a palavra “viagra” está presente. Calcule a probabilidade a partir dos dados apresentados na tabela abaixo.

Frequência	viagra		Total
	Sim	Não	
<i>spam</i>	4	16	20
<i>não spam</i>	1	79	80
Total	5	95	100

Exemplo 10.1

$$\begin{aligned}P(spam|viagra) &= \frac{P(spam \cap viagra)}{P(viagra)} \\&= \frac{P(viagra|spam)P(spam)}{P(viagra)} \\&= \frac{\frac{4}{20} \frac{20}{100}}{\frac{5}{100}} \\&= \frac{4}{5} \\&= 0,80\end{aligned}$$

O classificador Naive Bayes

O classificador Naive Bayes

- Vamos considerar agora que temos mais informações sobre uma instância (mais atributos coletados) para calcular a probabilidade *a posteriori* de que ela pertença à classe C .
- Por simplicidade, vamos considerar apenas três atributos A_1 , A_2 e A_3 . Então

$$P(C|A_1 \cap A_2 \cap A_3) = \frac{P(A_1 \cap A_2 \cap A_3|C)P(C)}{P(A_1 \cap A_2 \cap A_2)}. \quad (2)$$

- Essa fórmula é computacionalmente muito difícil de resolver.
 - À medida que são adicionados mais atributos, são necessárias quantidades enormes de memória para armazenar as probabilidades de todas as interseções entre os eventos possíveis.

O classificador Naive Bayes

- Para contornar esse problema, o método Naive Bayes assume independência entre os atributos condicionados à mesma classe. Isto leva ao resultado:

$$P(A_1 \cap A_2 \cap A_3 | C) = P(A_1 | C)P(A_2 | C)P(A_3 | C).$$

Assim, a [Equação 2](#) fica

$$P(C | A_1 \cap A_2 \cap A_3) = \frac{P(A_1 | C)P(A_2 | C)P(A_3 | C) P(C)}{P(A_1 \cap A_2 \cap A_3)}.$$

O classificador Naive Bayes

O algoritmo de classificação Naive Bayes pode ser definido da seguinte forma:

- Sejam A_1, A_2, \dots, A_n os valores dos n atributos de uma instância. A probabilidade de classificar essa instância como pertencente à classe C usando naive Bayes é

$$P(C|A_1, \dots, A_n) = \frac{P(C) \prod_{i=1}^n P(A_i|C)}{P(A_1, \dots, A_n)}$$

em que:

- $P(C)$ é a probabilidade de uma instância pertencer à classe C ;
- $P(A_i|C)$ é a probabilidade de ser observado A_i dada a ocorrência da classe C ;
- $P(A_1, \dots, A_n)$ é a probabilidade conjunta de A_1, \dots, A_n .

O classificador Naive Bayes

- Suponha que temos duas classes C_1 e C_2 para classificar uma instância considerando três atributos, A_1 , A_2 e A_3 .
- Então temos:

$$P(C_1 | A_1 \cap A_2 \cap A_3) = \frac{P(A_1 | C_1)P(A_2 | C_1)P(A_3 | C_1)P(C_1)}{P(A_1, A_2, A_3)}$$

e

$$P(C_2 | A_1 \cap A_2 \cap A_3) = \frac{P(A_1 | C_2)P(A_2 | C_2)P(A_3 | C_2)P(C_2)}{P(A_1, A_2, A_3)}$$

- Na prática, como o denominador para ambas as equações é o mesmo, os ignoramos para simplificar nossos cálculos e nos concentramos apenas nos numeradores.

O classificador Naive Bayes

- Então a probabilidade de uma instância ser classificada na classe C_1 é a probabilidade de ser C_1 dividida pela probabilidade de que seja tanto C_1 quanto C_2 .
- Vejamos um eexmplo para melhor compreensão.

Exemplo 10.2

Vamos expandir nosso filtro de spam do Exemplo 7.1, adicionando mais termos a serem monitorados: “viagra”, “dinheiro”, “compra” e “descadastrar”.

Verossimilhança	viagra (W_1)		dinheiro (W_2)		compra (W_3)		descadastrar (W_4)		Total
	Sim	Não	Sim	Não	Sim	Não	Sim	Não	
<i>spam</i>	$\frac{4}{20}$	$\frac{16}{20}$	$\frac{10}{20}$	$\frac{10}{20}$	$\frac{0}{20}$	$\frac{20}{20}$	$\frac{12}{20}$	$\frac{8}{20}$	20
<i>não spam</i>	$\frac{1}{80}$	$\frac{79}{80}$	$\frac{14}{80}$	$\frac{66}{80}$	$\frac{8}{80}$	$\frac{72}{80}$	$\frac{23}{80}$	$\frac{57}{80}$	80
Total	$\frac{5}{100}$	$\frac{95}{100}$	$\frac{24}{100}$	$\frac{76}{100}$	$\frac{8}{100}$	$\frac{91}{100}$	$\frac{35}{100}$	$\frac{65}{100}$	100

Um novo email é recebido e possui os termos “viagra” e “descadastrar”. Calcule a probabilidade do email ser *spam* e *não spam* usando naive Bayes.

Exemplo 10.2

- Probabilidade inicial para *spam*:

$$\begin{aligned} P(W_1 | spam)P(\neg W_2 | spam)P(\neg W_3 | spam)P(W_4 | spam)P(spam) &= \\ &= (4/20)(10/20)(20/20)(12/20)(20/100) \\ &= 0,012 \end{aligned}$$

- Probabilidade inicial para não *spam*:

$$\begin{aligned} P(W_1 | \neg spam)P(\neg W_2 | \neg spam)P(\neg W_3 | \neg spam)P(W_4 | \neg spam)P(\neg spam) &= \\ &= (1/80)(60/80)(71/80)(23/80)(80/100) \\ &= 0,002 \end{aligned}$$

- As probabilidades finais para *spam* e não *spam* são, respectivamente:

$$0,012/(0,012 + 0,002) = 0,857$$

$$0,002/(0,012 + 0,002) = 0,143$$

O estimador de Laplace

- Suponha agora que recebemos um email contendo os quatro termos do Exemplo 7.2: “viagra”, “dinheiro”, “compra” e “descadastrar”.
- Usando naive Bayes, a probabilidade de ser *spam* é

$$(4/20)(10/20)(0/20)(12/20)(20/100) = 0$$

- Enquanto a de não *spam* é

$$(1/80)(14/80)(8/80)(23/80)(80/100) = 0,000005$$

- Logo, a probabilidade final para *spam* e não *spam* ficam, respectivamente:

$$0/(0 + 0,000005) = 0$$

$$0,000005/(0 + 0,000005) = 1$$

O estimador de Laplace

- Os resultados indicam probabilidade zero de ser *spam* e 100% de não ser *spam*, mas isso parece improvável.
- Isso ocorreu porque nos dados de treino não foi observada a palavra “compra” em emails de *spam*.
- A solução é usar o estimador de Laplace, que adiciona pequenos valores às contagens para evitar probabilidades nulas e melhorar a precisão da classificação.
 - Em geral somamos 1 às frequências de cada atributo para evitar frequência zero.
 - Então, ao invés de calcularmos a probabilidade de um atributo A_i como a_i/N , calculamos

$$(a_i + 1)/(N + 1 \times d),$$

em que d é o número de atributos totais considerados.

Exemplo 10.3

Calcule as probabilidades do email ser *spam* ou não usando o estimador de Laplace.

Exemplo 10.3

- Probabilidade inicial de *spam*: $(5/24)(11/24)(1/24)(13/24)(20/100) = 0,0004$
- Probabilidade inicial de não *spam*: $(2/84)(15/84)(9/84)(24/84)(80/100) = 0,0001$

- Probabilidade final de *spam*: $0,0004/(0,0004 + 0,0001) = 0,80$
- Probabilidade final de não *spam*: $0,0001/(0,0004 + 0,0001) = 0,20$

Atributos numéricos

- O método Naive Bayes requer que os atributos sejam categóricos.
- Se um atributo for numérico, devemos discretizá-lo, criando categorias.
- Para isso, devermos explorar os dados.



Vantagens e desvantagens

Vantagens

- Simples, rápido e muito efetivo.
- Bom desempenho com dados ruidosos e ausentes.
- Necessidade de poucos exemplos para o treinamento, mas também funciona bem com um grande número de exemplos.
- Fácil de obter a probabilidade estimada para uma previsão.

Desvantagens

- Baseia-se frequentemente em uma suposição falha de características igualmente importantes e independentes.
- Não é ideal para conjuntos de dados com muitas características numéricas.
- As probabilidades estimadas são menos confiáveis do que as classes previstas.

Agora vamos fazer no R...