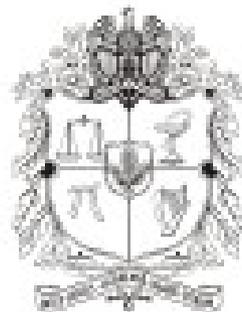


Diplomado en Inteligencia de Negocios Módulo

Minería de Datos



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Análisis Supervisado III

Modelos Probabilísticos

Diplomado en Inteligencia de Negocios
Módulo 3



Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificador Bayesiano
- Naive Bayes
- Red de creencias
- Clasificación sensible al costo

Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificador Bayesiano
- Naive Bayes
- Red de creencias
- Clasificación sensible al costo

Probabilidad

- Formalización de la noción intuitiva de la posibilidad de que un evento ocurra

$$P(E) = \frac{\textit{número de veces que sucede E}}{\textit{posibles eventos}}$$

- Cuál es la probabilidad de obtener el número 6 si lanzo un dado?
- Cuál es la probabilidad de obtener 10 o más si lanzamos dos dados?
- Variable aleatoria: una variable que puede tomar diferentes valores de acuerdo con una distribución de probabilidad

Probabilidad Conjunta

- Es la probabilidad de que dos eventos sucedan a la vez:

$$P(X=x, Y=y)$$

probabilidad de que X y Y tomen los valores x y y a la vez

- $P(\text{dado}_1=4, \text{dado}_2=6) = ?$

Probabilidad Condicional

- Probabilidad de que una variable aleatoria pueda tomar un valor particular dado el valor de otra variable aleatoria

$$P(Y=y \mid X=x)$$

- se refiere a la probabilidad que la variable Y puede tomar el valor de y dado que la variable X toma el valor de x

Probabilidad Condicional

- Cuál es la probabilidad de obtener 10 al lanzar un par de dados si sé que uno de los dados cayo en 4?

$$\textit{suma} = \textit{dado_1} + \textit{dado_2}$$

$$P(\textit{suma}=10 \mid \textit{dado_1}=4) = ?$$

Teorema de Bayes

- Las probabilidades condicionales de X y Y están relacionadas:

$$P(X,Y) = P(Y|X) P(X) = P(X|Y) P(Y)$$

- **Teorema de Bayes**

$$P(Y|X) = P(X|Y) \cdot P(Y) / P(X)$$

- Ejercicio

2 equipos. Equipo 0 gana el 65% de las veces, equipo 1 gana 35% de las veces. De los juegos ganados por el equipo 0, el 30% son jugados en la cancha del equipo 1. El 75%, de las victorias del equipo 1 son ganados cuando juegan en casa. Si el equipo 1 juega de local, cuál equipo es el favorito a ganar?

Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificadores Bayesiano
- Naive Bayes
- Red de creencias
- Clasificación sensible al costo

Clasificador Bayesiano

- Considere que cada atributo y la etiqueta de clase son variables aleatorias
- Dado un registro con atributos (A_1, A_2, \dots, A_n)
- El objetivo es predecir la clase C
- Específicamente, nosotros deseamos encontrar el valor de C que maximice $P(C | A_1, A_2, \dots, A_n)$
- Podemos estimar $P(C | A_1, A_2, \dots, A_n)$ directamente a partir de los datos?

Solución

- calcule la probabilidad *a posteriori* $P(C \mid A_1, A_2, \dots, A_n)$ para todos los valores de C usando el teorema de Bayes:

$$P(C \mid A_1 A_2 \dots A_n) = \frac{P(A_1 A_2 \dots A_n \mid C) P(C)}{P(A_1 A_2 \dots A_n)}$$

- Escoja el valor de C que maximice $P(C \mid A_1, A_2, \dots, A_n)$
- Equivalente a escoger el valor de C que maximice $P(A_1, A_2, \dots, A_n \mid C) P(C)$
- Cómo se estima $P(A_1, A_2, \dots, A_n \mid C)$?

Problema de tomar una decisión

Dada las condiciones del clima, es posible jugar
tenis?

Outlook	Temperature	Humidity	Windy	Class
sunny	hot	high	false	N
sunny	hot	high	true	N
overcast	hot	high	false	P
rain	mild	high	false	P
rain	cool	normal	false	P
rain	cool	normal	true	N
overcast	cool	normal	true	P
sunny	mild	high	false	N
sunny	cool	normal	false	P
rain	mild	normal	false	P
sunny	mild	normal	true	P
overcast	mild	high	true	P
overcast	hot	normal	false	P
rain	mild	high	true	N

Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificadores Bayesiano
- Naïve Bayes
- Red de creencias
- Clasificación sensible al costo

Clasificador Naïve Bayes

- Asume independencia entre los atributos A_i cuando la clase es dada:
 - $P(A_1, A_2, \dots, A_n | C) = P(A_1 | C) P(A_2 | C) \dots P(A_n | C)$
 - Se debe estimar $P(A_i | C)$ para todo A_i y C .
 - Un nuevo ejemplo es clasificado como C_j si $P(C_j) \prod P(A_i | C_j)$ es máximo.

Cómo Estimar las Probab. a Partir de los Datos?

Tid	Refund	Marital Status	Taxable Income	Evade
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

□ Clase: $P(C) = N_c/N$

■ ej., $P(\text{No}) = 7/10,$
 $P(\text{Yes}) = 3/10$

□ Para atributos discretos:

$$P(A_i | C_k) = |A_{ik}| / N_c$$

$|A_{ik}|$ es el número de instancias con atributo A_i y pertenecientes a C_k

Ejemplos:

$$P(\text{Status}=\text{Married}|\text{No}) = 4/7$$
$$P(\text{Refund}=\text{Yes}|\text{Yes})=0$$

Cómo Estimar las Probab. a Partir de los Datos?

- Para atributos continuos:
 - **Discretizar:** el rango en bins
 - un atributo ordinal por bin
 - viola la suposición de independencia
 - **Separación:** $(A < v)$ o $(A > v)$
 - Escoger solo uno de los dos intervalos como nuevo atributo
 - **Estimación de la distribución de probabilidad:**
 - Asuma que el atributo tiene una distribución normal
 - Use los datos para estimar los parámetros de la distribución (ej., media y desviación estándar)
 - Una vez que la distribución de probabilidad se conoce, se puede usar para estimar $P(A_i|c)$

Cómo Estimar las Probab. a Partir de los Datos?

<i>Tid</i>	Refund	Marital Status	Taxable Income	Evade
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

□ Distribución normal:

$$P(A_i | c_j) = \frac{1}{\sqrt{2\pi\sigma_{ij}^2}} e^{-\frac{(A_i - \mu_{ij})^2}{2\sigma_{ij}^2}}$$

■ Uno por cada par (A_i, c_i)

□ Para (Income, Class=No):

■ Si Class=No

□ media muestral = 110

□ varianza muestral = 2975

$$P(\text{Income} = 120 | \text{No}) = \frac{1}{\sqrt{2\pi(54.54)}} e^{-\frac{(120-110)^2}{2(2975)}} = 0.0072$$

Ejemplo del Clasificador Naïve Bayes

$$X = (\text{Refund} = \text{No}, \text{Married}, \text{Income} = 120\text{K})$$

naive Bayes Classifier:

$$P(\text{Refund}=\text{Yes}|\text{No}) = 3/7$$

$$P(\text{Refund}=\text{No}|\text{No}) = 4/7$$

$$P(\text{Refund}=\text{Yes}|\text{Yes}) = 0$$

$$P(\text{Refund}=\text{No}|\text{Yes}) = 1$$

$$P(\text{Marital Status}=\text{Single}|\text{No}) = 2/7$$

$$P(\text{Marital Status}=\text{Divorced}|\text{No}) = 1/7$$

$$P(\text{Marital Status}=\text{Married}|\text{No}) = 4/7$$

$$P(\text{Marital Status}=\text{Single}|\text{Yes}) = 2/7$$

$$P(\text{Marital Status}=\text{Divorced}|\text{Yes}) = 1/7$$

$$P(\text{Marital Status}=\text{Married}|\text{Yes}) = 0$$

For taxable income:

If class=No: sample mean=110
 sample variance=2975

If class=Yes: sample mean=90
 sample variance=25

- $P(X|\text{Class}=\text{No}) = P(\text{Refund}=\text{No}|\text{Class}=\text{No})$
 $\times P(\text{Married}|\text{Class}=\text{No})$
 $\times P(\text{Income}=120\text{K}|\text{Class}=\text{No})$
 $= 4/7 \times 4/7 \times 0.0072 = 0.0024$
- $P(X|\text{Class}=\text{Yes}) = P(\text{Refund}=\text{No}|\text{Class}=\text{Yes})$
 $\times P(\text{Married}|\text{Class}=\text{Yes})$
 $\times P(\text{Income}=120\text{K}|\text{Class}=\text{Yes})$
 $= 1 \times 0 \times 1.2 \times 10^{-9} = 0$

Puesto que $P(X|\text{No})P(\text{No}) > P(X|\text{Yes})P(\text{Yes})$
entonces $P(\text{No}|X) > P(\text{Yes}|X)$
 $\Rightarrow \text{Clase} = \text{No}$

Clasificador Naïve Bayes

- Si una de las probabilidades condicionales es 0, entonces toda la expresión se vuelve 0
- Estimación de la probabilidad:

$$\text{Original: } P(A_i|C) = \frac{N_{ic}}{N_c}$$

c: número de clases

$$\text{Laplace: } P(A_i|C) = \frac{N_{ic} + 1}{N_c + c}$$

p: probabilidad a priori

m: parámetro

$$\text{m-estimate: } P(A_i|C) = \frac{N_{ic} + mp}{N_c + m}$$

Naïve Bayes (Recapitulación)

- Robusto a ejemplos ruidosos
- Maneja valores faltantes simplemente ignorando la instancia durante los cálculos de la estimación de probabilidad
- Robusto a atributos irrelevantes
- La suposición de independencia puede no cumplirse para algunos atributos:
 - Se deben usar otras técnicas tales como redes de creencias Bayesianas

Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificadores Bayesiano
- Naive Bayes
- Red de creencias
- Clasificación sensible al costo

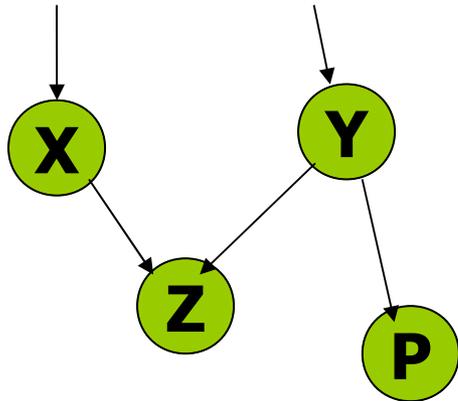
Bayesian Belief Networks

Redes de Creencias Bayesianas

- Modelar la probabilidad condicional de clases $P(X|Y)$ sin el supuesto de independencia
- Permite **especificar** qué par de atributos son condicionalmente dependientes
- Pasos:
 - Representación y construcción del modelo
 - Estimación de probabilidades condicionales
 - Inferencia sobre el modelo

Red de Creencias

- Un modelo gráfico de relaciones causales:
 - Representan dependencia condicional entre las variables
 - Variables no explícitamente relacionadas se consideran condicionalmente independientes



- Nodos: variables aleatorias
- Enlaces: dependencias
- X y Y son los padres de Z, y Y es el padre de P
- No hay dependencia entre Z y P
- No tiene bucles o ciclos

Ejemplo Red de Creencia

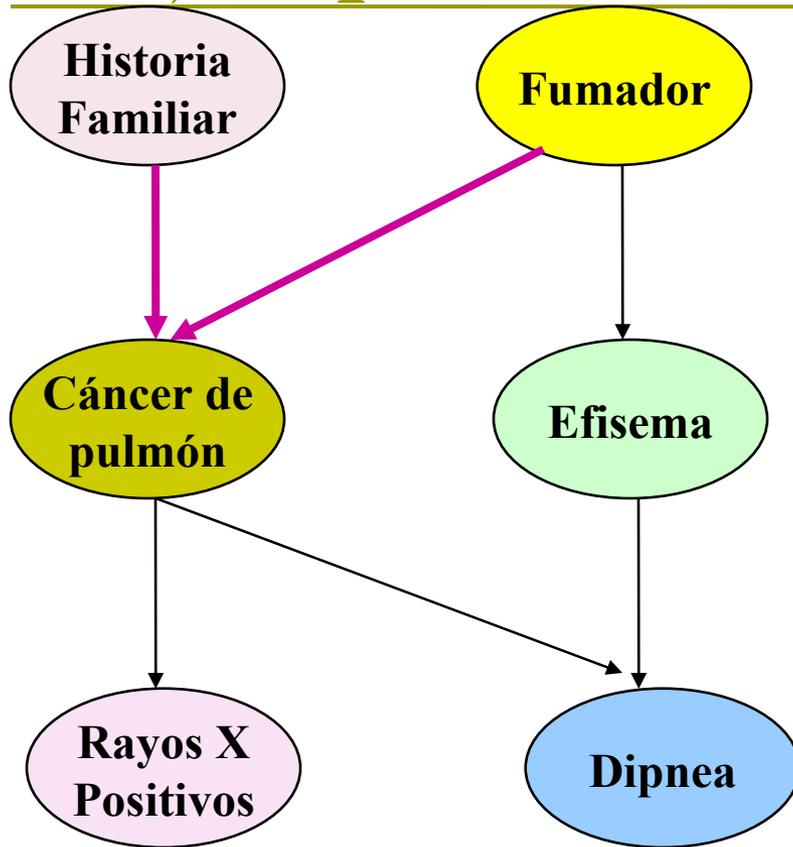


Tabla de probabilidad condicional (TPC) para la variable cáncer de pulmón:

	(HF, F)	(HF, ~F)	(~HF, F)	(~HF, ~F)
CP	0.8	0.5	0.7	0.1
~CP	0.2	0.5	0.3	0.9

La derivación de la probabilidad de una combinación particular de valores de \mathbf{X} , desde TPC:

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{Padres}(Y_i))$$

$$P(HF, F, CP, E, RXP, D) = P(HF)P(F)P(CP|HF, F)P(E|F)P(RXP|CP)P(D|CP, E)$$

Inferencia

- Diagnosticar si una persona tiene Cáncer de Pulmón:
 - Sin información previa: $P(\text{CP})$
 - Rayos X Positivos: $P(\text{CP}|\text{RXP})$
 - Rayos X Positivos, Fumador, No Dipnea: $P(\text{CP}|\text{RXP}, \text{F}, \sim \text{D})$
- En todos los casos se puede calcular usando la probabilidad conjunta total y las leyes de probabilidad

Entrenamiento de Redes Bayesianas

- Varios escenarios:
 - Dando la estructura de la red y todas las variables observables: aprende solo las TPCs.
 - La estructura de la red se conoce, algunas variables están ocultas: método del gradiente descendente (greedy hill-climbing), análogo al aprendizaje neural de la red.
 - La estructura de la red es desconocida, todas las variables son observables: buscar a través del espacio del modelo para reconstruir la topología de la red.
 - Estructura desconocida, todas las variables están ocultas: no se conocen buenos algoritmos para éste propósito.
- Ref. D. Heckerman: Bayesian networks for data mining

Características

- Modelo grafico
- Construir la red puede ser costoso. Sin embargo, una vez construida la red, adicionar una nueva variable es directo
- Trabajan bien con datos perdidos (sumando o integrando las probabilidades)
- El modelo es robusto a overfitting

Agenda

- Repaso de probabilidad
- Modelos Bayesianos
- Clasificadores Bayesiano
- Naive Bayes
- Red de creencias
- Clasificación sensible al costo

Clasificación Sensible al Costo

Area	Ejemplo
Marketing	<input type="checkbox"/> Comprador / no Comprador
Medicina	<input type="checkbox"/> Enfermo / no Enfermo
Finanzas	<input type="checkbox"/> Prestar / no Prestar
Spam	<input type="checkbox"/> Spam / no Spam

Suponer que los Errores Son Igualmente Costosos Pueden Llevar a Malas Decisiones

Examples

Marketing

- El costo de hacerle una oferta a un no comprador es pequeña comparada con no contactar un comprador

Finance

- El costo de un mal prestamo es mayor que negarle un prestamo aun buen cliente

Spam

- Rechazar correo que no sea Spam es más costoso que aceptar correo Spam

Matriz de Costos

Actual

		Actual		
		Sunny	Snowy	Rainy
Predicted	Sunny	0	10	15
	Snowy	1	1	11
	Rainy	2	2	2

Costos Dependientes Fraude con Tarjeta de Créd.

		Real	
		Fraude	No fraude
Predicho	Rechazo	20	- 20
	Aprobar	-X	(0.2)X

$x = \text{valor transacción}$

Aprendizaje Sensitivo al Costo

- Aprendizaje no sensitivo al costo:

$$\max_{C_i} P(C_i | A_1, \dots, A_n)$$

- Aprendizaje sensitivo al costo:

- Escoger acción que minimice el costo esperado

$$\min_{C_i} \sum_{C_j \neq C_i} P(C_j | A_1, \dots, A_n) \text{Costo}(C_j, C_i)$$

- $\text{Costo}(C_j, C_i) =$ costo de clasificar como C_i cuando realmente es C_j
- Los dos enfoques son equivalentes cuándo los costos son iguales para todos los errores

Metacost

- Es un algoritmo que permite volver cualquier clasificador sensitivo al costo
- Se debe especificar una matriz de costos
- El algoritmo reetiqueta los ejemplos de entrenamiento de manera que el costo esperado se minimice
- Domingos. *MetaCost: A General Method for Making Classifiers Cost-Sensitive*. In Proceedings of the Fifth International Conference on Knowledge Discovery and Data Mining (KDD-99). 1999.

Bibliografía

- B. Zadrozny, J. Langford, and N. Abe. Cost-Sensitive Learning by Cost-Proportionate Example Weighting. In Proceedings of the 2003 IEEE International Conference on Data Mining, 2003.
- Alpaydin, E. 2004 Introduction to Machine Learning (Adaptive Computation and Machine Learning). The MIT Press.
- Tan, Steinbach and Kumar, Introduction to Data Mining, Addison Wesley, 2006
- Alan Abrahams, An Introduction to Cost-Sensitive Learning , Lecture Slides,
http://opim.wharton.upenn.edu/~asa28/opim_410_672_spring05/opim_410_guest_lecture_dan_fleder_cost_sensitive_learning.ppt

Ejemplo

- X variable aleatoria que representa el equipo local
- Y variable aleatoria que representa el ganador
- Probabilidad que equipo 0 gane: $P(Y=0) = 0.65$
- Probabilidad que equipo 1 gane: $P(Y=1) = 0.35$
- Probabilidad de que si el equipo 1 gana esté jugando como local:

$$P(X=1 | Y=1) = 0.75$$

- Probabilidad de que si el equipo 0 gana esté jugando como visitante:

$$P(X=1 | Y=0) = 0.3$$

Ejemplo

□ Objetivo

$P(Y=1|X=1)$ probabilidad condicional de que el equipo 1 gane el siguiente juego estando como local, y comparar con $P(Y=0|X=1)$

□ Usando Bayes

$$\begin{aligned} P(Y=1|X=1) &= P(X=1|Y=1) P(Y=1) / P(X=1) \quad \text{Ley de probabilidad total} \\ &= P(X=1|Y=1) P(Y=1) / P(X=1, Y=1) + P(X=1, Y=0) \\ &= P(X=1|Y=1) P(Y=1) / P(X=1|Y=1)P(Y=1) + P(X=1|Y=0)P(Y=0) \\ &= 0.75 \times 0.35 / (0.75 \times 0.35 + 0.3 \times 0.65) = 0.5738 \end{aligned}$$

$$\square P(Y=0|X=1) = 1 - P(Y=1|X=1) = 0.4262$$

Equipo1 tiene mas oportunidad de ganar