

Modelos Gráficos Probabilísticos

Descubrimiento de conocimiento a Partir de Datos


Dr. Marcelo G. Armentano
ISISTAN, Fac. de Cs. Exactas, UNICEN

Agenda

- Introducción
- Redes de Bayes
- Modelos de Markov

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Modelos Gráficos Probabilísticos



Teoría de probabilidad MGP Teoría de grafos

- Forma natural de hacer frente a:
 - Incertidumbre
 - Complejidad

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Modelos Gráficos Probabilísticos

- Representación
 - Como representamos de manera compacta una distribución de probabilidades conjunta
- Inferencia
 - Como inferimos los estados ocultos de un sistema basándonos en observaciones parciales
- Aprendizaje
 - Como estimamos los parámetros y la estructura del modelo

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Redes de Bayes

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Agenda

- Introducción
- Redes de Bayes
 - Definición
 - Ejemplos
 - Conceptos de Probabilidades
 - Utilización
 - Inferencia Probabilística
 - Construcción
 - Aprendizaje
- Modelos de Markov

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Redes de Bayes

- Las Redes de Bayes se usan para modelar dominios que contengan incertidumbre.
- Se conocen también como:
 - Redes Bayesianas
 - Redes probabilísticas causales
 - Redes de creencias
 - Redes de creencias bayesianas

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Incertidumbre: fuentes

- Conocimiento incompleto del dominio
- Entendimiento/comprensión incorrecta del dominio
- Relaciones en el dominio de naturaleza no determinística (ej: enfermedades y síntomas)
- Términos involucrados muy vagos (grande, hermosa, dolor)
- Realización de algún tipo de abstracción
- Naturaleza aleatoria de los mecanismos que rigen el comportamiento del dominio (ej. modelado de usuarios)

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Conceptos

- Una Red de Bayes consiste de un conjunto de **nodos** y de un conjunto de **arcos dirigidos** entre estos nodos.
- Los arcos reflejan relaciones **causa-efecto** dentro del dominio. Estos efectos normalmente no son determinísticos (ej: enfermedad \rightarrow síntoma).
- La "fuerza" de un efecto es modelada como una **probabilidad**.
- La base matemática está dada por el **Teorema de Bayes**.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Definición

- Una **Red Bayesiana** es un **grafo dirigido acíclico** (GDA) donde cada nodo representa una **variable aleatoria** y los arcos entre los nodos representan **dependencias probabilísticas** entre las variables. Cada nodo contiene los **estados** de la variable que representa y una **tabla de probabilidad condicional** (CPT). La CPT de un nodo contiene las probabilidades de que el nodo esté en un estado específico dados los estados de sus padres.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Nodos

- Un nodo representa una variable aleatoria **discreta** con un número finito de estados o una variable aleatoria **continua** (distribución Gaussiana).
- Si un nodo no tiene padres, el nodo contendrá una **tabla de probabilidad marginal**.
 - Si el nodo es discreto, contiene una distribución de probabilidad sobre los estados de la variable que representa.
 - Si el nodo es continuo, contiene una función de densidad Gaussiana (dada por la media y la varianza) para la variable aleatoria que representa.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Tablas de probabilidad

- Si el nodo tiene padres, contiene una tabla de probabilidad condicional (CPT).
 - Si el nodo es **discreto**, cada celda en la CPT de un nodo contiene una probabilidad condicional para cada estado en que pueda estar el nodo dada una configuración específica de los estados de sus padres.
 - Si el nodo es **continuo**, la CPT contiene una media y una varianza para cada configuración de los estados de sus padres discretos y un coeficiente de regresión por cada padre continuo.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Ejemplo: Apple Jack

- Un día Apple Jack descubre que su mejor árbol de manzanas está perdiendo sus hojas. Entonces quiere saber qué está pasando. Él sabe que si el árbol está seco es muy común que pierda sus hojas. Por el otro lado, perder las hojas puede ser un indicio de que el árbol esté enfermo.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo: Apple Jack



p(Pierde/ Seco, Enfermo)	Seco=si Enfermo=si	Seco=si Enfermo=no	Seco=no Enfermo=si	Seco=no Enfermo=no
Pierde=si	0.95	0.85	0.90	0.02
Pierde=no	0.05	0.15	0.10	0.98

Dependencias Causales

- Cuando existe una **dependencia causal** de un nodo A a un nodo B, se espera que cuando A está en un cierto estado esto tiene un **impacto** en el estado de B.
- En el ejemplo, existe un vínculo causal de "Enfermo" a "Pierde hojas" porque cuando un árbol está enfermo puede causar que pierda las hojas.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Independencia condicional

- Dos conjuntos de variables A y B son (condicionalmente) independientes de un tercer conjunto C si cuando los valores de C son conocidos, el conocimiento acerca de B no provee más información sobre los valores de A.

$$p(A/B,C) = p(A/C)$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo 2: Asia



$$p(\text{Bronchitis}/\text{Visit Asia}, \text{Smoker}) = p(\text{Bronchitis}/\text{Smoker})$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Distribución de probabilidad conjunta

Dado un conjunto de variables V_1, V_2, \dots, V_k cuyos valores se denotan v_1, v_2, \dots, v_k , una expresión de la forma $p(V_1, V_2, \dots, V_k)$ se denomina función de probabilidad conjunta sobre las variables V_1, V_2, \dots, V_k .



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo 3: Robot

- Un robot es capaz de levantar una bandeja si la bandeja es liviana y si las baterías de la fuente de energía del robot están cargadas. Si estas condiciones se satisfacen, entonces cuando el robot trata de levantar la bandeja, mueve sus brazos. Se determina si la batería está cargada mediante un medidor.



¿variables?

¿estados?

¿relaciones?



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo 3: Robot

$P(B) = 0.95$ $P(L) = 0.7$
 $P(G/B) = 0.95$ $P(M/B, L) = 0.9$
 $P(G/-B) = 0.1$ $P(M/B, -L) = 0.05$
 $P(M/-B, L) = 0.0$
 $P(M/-B, -L) = 0.0$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo 3: Robot

- $P(B, M, L, G)$
- 4 variables binarias binarias \rightarrow 16 probabilidades

(B,M,L,G)	Prob. Conj.
(V,V,V,V)	0.5686
(V,V,V,F)	0.0299
(V,V,F,V)	0.0135
(V,V,F,F)	0.0007
...	...

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo 3: Robot

- $P(A, B, D, L, S, X, T)$
- 7 variables binarias \rightarrow 128 Probs. Conjuntas!!!!



Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Problema de la probabilidad conjunta

- Se necesitan en el orden de 2^k valores para definir la función de probabilidad conjunta.
- Solución
 - Las relaciones de independencia condicional entre las variables contribuyen a la disminución de la complejidad del problema

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Redes de Bayes


- Representación compacta de distribuciones de probabilidades via independencia condicional
- Parte cualitativa:
 - Grafo dirigido acíclico (gda)
 - Nodos - variables aleatorias
 - Arcos - influencia directa
- Parte cuantitativa:
 - Conjunto de distribuciones de probabilidades condicionales
 - Juntos definen una única distribución conjunta de manera factorizada



E	B	$P(A E,B)$
e	b	0.9 0.1
e	\bar{b}	0.2 0.8
\bar{e}	b	0.9 0.1
\bar{e}	\bar{b}	0.01 0.99

$P(B, E, A, C, R) = P(B)P(E)P(A|B, E)P(R|E)P(C|A)$

Semántica de las Redes de Bayes



Independencias condicionales en la estructura de la red + Modelos de probabilidades locales = Distribución de probabilidad conjunta sobre un dominio

$$P(s, \bar{c}, l, \bar{e}, \bar{x}, d) = P(s) P(\bar{c}) P(l|s) P(e|s, \bar{c}) P(\bar{x}|l) P(d|l, \bar{e})$$

- Representación natural y compacta

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Agenda

- Definición
- Ejemplos
- Conceptos de Probabilidades
- **Utilización**
- **Inferencia Probabilística**
- Construcción
- Aprendizaje

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Utilización de Redes de Bayes

- Obtener los valores de probabilidades de ciertas variables de interés a partir de la información (**evidencia**) del estado de otras variables.
- Ej: Sabemos que el árbol está perdiendo sus hojas,
 - ¿Cuál es la probabilidad de que el árbol esté enfermo?
 - ¿Cuál es la probabilidad de que el árbol esté seco?



Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Inferencia probabilística

- Consiste en calcular probabilidades de interés a partir de una distribución de probabilidades conjunta.
- La estructura de la red de Bayes permite calcular cualquier probabilidad de interés; donde la independencia condicional simplifica el cálculo

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Inferencia en Redes de Bayes

- La inferencia consiste en el cálculo de los resultados a una consulta (distribución de probabilidades) con respecto a una red dada y a la presencia de cierta evidencia



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo de inferencia

Consulta: ¿Está enfermo el árbol?



Evidencia: el árbol pierde las hojas

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo de inferencia

- **Consulta:** ¿Está enfermo el árbol?
- **Evidencia:** el árbol pierde las hojas

Enfermo		Seco		Enfermo		Seco	
True	10.0	True	10.0	True	49.399	True	46.943
False	90.0	False	90.0	False	50.600	False	53.056

Pierde Hojas		Pierde Hojas	
True	8.320	True	100.0
False	81.68	False	0.0

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Teorema de Bayes

- El teorema de Bayes nos dice como obtener una probabilidad a posteriori en una hipótesis V_i luego de la observación de alguna evidencia V_j , dadas la probabilidad a priori de V_i y la probabilidad de observar V_j dado V_i .

$$p(V_i / V_j) = \frac{p(V_j / V_i) p(V_i)}{p(V_j)}$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo del Teorema de Bayes

- Si una persona ve que un brazo del robot se está moviendo, se quiere obtener la probabilidad de que esto haya ocurrido cuando la batería está descargada.
- Evidencia: $p(M = V)$
- Probabilidad a priori: $p(B = F)$
- Probabilidad condicional: $p(M = V / B = F)$

- $P(B = F / M = V) = p(M = V / B = F) p(B = F) / p(M = V)$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Inferencia en Redes de Bayes

- Inferencia causal o top-down
- Inferencia de diagnóstico o bottom-up

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Inferencia causal

- Probabilidad de que el brazo se mueva dado que la bandeja es liviana

Consulta \rightarrow $P(M/L)$ Evidencia

$$p(M/L) = p(M, B/L) + p(M, \neg B/L) \quad (\text{expansión})$$

$$= p(M/B, L) P(B/L) + p(M/\neg B, L) P(\neg B/L)$$

$$= p(M/B, L) P(B) + p(M/\neg B, L) P(\neg B)$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Inferencia de diagnóstico

- Probabilidad de que la bandeja esté pesada dado que el brazo no se mueve

Causa \rightarrow $P(\neg L/\neg M)$ Efecto

$$p(\neg L/\neg M) = p(\neg M/\neg L) p(\neg L) / p(\neg M) \quad \text{Bayes}$$

Se resuelve $p(\neg M/\neg L)$ usando razonamiento causal

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Inferencia exacta

- A pesar de poder explotar las propiedades de la red, la inferencia probabilística exacta en una red de Bayes arbitraria es NP-hard.
- Para muchas aplicaciones, donde las redes son pequeñas o pueden simplificarse, la complejidad puede no ser fatal.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmos de Inferencia

- Existen numerosos algoritmos de inferencia implementados
- Centrados en operaciones algebraicas
 - Variable Elimination [Zhang96]
 - Bucket Elimination [Dechter99]
 - SPI [D'Ambrosio94]
- Centrados en propiedades gráficas
 - Junction trees [Jensen96]

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Agenda

- Definición
- Ejemplos
- Conceptos de Probabilidades
- Utilización
- Inferencia Probabilística
- **Construcción**
- **Aprendizaje**

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Construcción de la red

- Ingeniería del Conocimiento
 - Un experto en el dominio identifica los aspectos cualitativos (y a veces cuantitativos) del problema
 - Codificar el conocimiento existente de expertos en una red
 - Usar una base de datos para actualizar este conocimiento
 - refinar el conocimiento experto original e identificar nuevas relaciones



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Construcción de la red

- Determinar las **variables** que intervienen en el modelo
- Determinar cada uno de los **estados** o valores que pueden tomar las variables
- Determinar las relaciones (**dependencias**) entre las variables
- Construir un GDA que codifique las aserciones de independencia condicional

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Construcción de la red

- Cómo obtener los valores de las probabilidades?
 - Conocimiento de expertos en el dominio
 - Estudios estadísticos
 - Derivados analíticamente
 - Aprenderlos a partir de los datos crudos


Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Construcción de la red

- Cómo obtener la estructura de la red?
 - A partir del conocimiento de un experto
 - Algoritmos de aprendizaje en Redes de Bayes
 - Datos completos o incompletos
 - Estructura conocida o desconocida


Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje de Redes de Bayes



Dr. Marcelo G. Armentano


Estructura conocida, datos completos



- La estructura de la red está especificada
 - Se necesitan estimar los parámetros (probabilidades)
- Los datos no contienen valores faltantes

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Estructura desconocida, datos completos



- La estructura de la red no está especificada
 - Se necesitan seleccionar los arcos y estimar los parámetros
- Los datos no contienen valores faltantes


Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Estructura conocida, datos incompletos



- La estructura de la red está especificada
- Los datos contienen valores faltantes
 - Se necesitan considerar asignaciones a los valores faltantes

Estructura desconocida, datos incompletos



- La estructura de la red no está especificada
 - Se necesitan seleccionar los arcos y estimar los parámetros
- Los datos contienen valores faltantes
 - Se necesitan considerar asignaciones a los valores faltantes

Aprendizaje de Redes de Bayes

- Aprendizaje paramétrico
 - Aprender los parámetros que describen el grado de dependencia entre las variables del dominio
- Aprendizaje estructural
 - Aprender las dependencias entre las variables que intervienen en el problema

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje paramétrico

- Aprendizaje Adaptativo
 - Se utiliza cuando se quieren adaptar todas o algunas de las tablas de probabilidad condicional a partir de un nuevo conjunto de datos.
- Aprendizaje Batch
 - Se utiliza cuando se quieren generar las tablas de probabilidad condicional a partir de los datos. Ej: EM (Expectation Maximization)

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje adaptativo

- La adaptación es el proceso de refinar las probabilidades condicionales especificadas en la Red de Bayes teniendo en cuenta los resultados de experimentos o casos reales.
- Se utilizan tablas de experiencia y/o tablas de desvanecimiento.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Aprendizaje adaptativo

- Un paso del proceso de aprendizaje adaptativo consiste de:
 - ingresar evidencia,
 - propagar la evidencia,
 - actualizar (adaptar) las tablas de probabilidad condicional y las tablas de experiencia



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje adaptativo con tablas de experiencia



$$P(\text{Smoker}=\text{yes}) = \frac{\#\text{yes}}{\#\text{yes} + \#\text{no}} = 10 / 15 = 0.667$$

$$P(\text{Smoker}=\text{no}) = \frac{\#\text{no}}{\#\text{yes} + \#\text{no}} = 5 / 15 = 0.333$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

- Utiliza tablas de experiencia
- Suposiciones
 - Independencia Global
 - Independencia Local
- Sean:
 - $p(A|b_i, c_j) = (x_i, x_j)$
 - (n_1, n_2) las experiencias de A
 - $s = n_1 + n_2$ cantidad total de experiencias
 - $p(A|b_i, c_j) = (\frac{n_1}{s}, \frac{n_2}{s})$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

- Caso 1
- Tenemos una nueva experiencia e con:
 - $B=b_i$,
 - $C=c_j$
 - $A=a_i$
- Luego,
 - $n_i=n_i+1$
 - $s=s+1$
 - $p(A|b_i, c_j) = \left(\frac{n_i+1}{s+1}, \frac{n_2}{s+1}\right)$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

- Caso 2
- Tenemos una nueva experiencia e con:
 - $B=b_i$,
 - $C=c_j$
 - de A sólo sabemos $p(A|e) = p(A|b_i, c_j, e) = (y_1, y_2)$
- Luego,
 - $n_k=n_k+y_k$
 - $s=s+1$
 - $x_k = \frac{n_k + y_k}{s+1}$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

- Caso general
- Tenemos una nueva experiencia e con:
 - $p(b_i, c_j | e) = z$
 - $p(A|b_i, c_j, e) = (y_1, y_2)$
- Luego,
 - $n_k=n_k+z \cdot y_k$
 - $s=s+z$
 - $x_k = \frac{n_k + y_k \cdot z}{s+z}$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

- Ejemplo

	B		
	true	false	
true	0.6	0.3	
false	0.4	0.7	
Experiences	10	10	→ S=20

n_1 n_2

Como $P(A=true|B=true) = 0.6$
 Tenemos

- $N(A=true|B=true) = 0.6 * 10 = 6$
- $N(A=true|B=false) = 0.3 * 10 = 3$

El total de las cuentas para la variable A:
 $N(true) = 6 + 3 = 9$
 $N(false) = 4 + 7 = 11.$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

Después de una experiencia con:

- A=true
- B=true

Obtenemos

$$p(A=true|B=true) = \frac{6+1.0*1.0}{11} = 0.63$$

$$p(A=false|B=true) = \frac{4+0.0*1.0}{11} = 0.37$$

$$p(A=true|B=false) = \frac{3+1.0*0.0}{10} = 0.3$$

$$p(A=false|B=false) = \frac{7+0.0*0.0}{10} = 0.7$$



	B	
	true	false
true	0.63	0.3
false	0.37	0.7
Experiences	11	10

$x_k = \frac{n_k + y_k \cdot z}{s+z}$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Fractional Updating

Si solo tenemos evidencia de A=true

Obtenemos

$$p(A=true|B=true) = \frac{6+1.0*0.67}{10.67} = 0.625$$

$$p(A=false|B=true) = \frac{4+0.0*0.67}{10.67} = 0.375$$

$$p(A=true|B=false) = \frac{3+1.0*0.33}{10.33} = 0.32$$

$$p(A=false|B=false) = \frac{7+0.0*0.33}{10.33} = 0.68$$



	B	
	true	false
true	0.625	0.32
false	0.375	0.68
Experiences	10.67	10.33

$x_k = \frac{n_k + y_k \cdot z}{s+z}$


Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje adaptativo con tablas de desvanecimiento

- A veces, las observaciones viejas no son tan importantes como las nuevas en el proceso de adaptación. Entonces, tenemos que “desaprender” u “olvidar” algunas de ellas.
- Las observaciones nuevas son más importantes que las viejas, y por lo tanto se les debe dar más peso durante la adaptación.
- Se introduce un factor de desvanecimiento, que indica la tasa con la cual se olvidan las observaciones previas
 - 0 no hay adaptación
 - 1 no hay desvanecimiento.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje adaptativo con tablas de desvanecimiento



$$P(\text{Smoker}=\text{yes}) = \frac{\#\text{yes}}{\#\text{yes} + \#\text{no}} = \frac{10}{15} = 0.667$$

$$P(\text{Smoker}=\text{no}) = \frac{\#\text{no}}{\#\text{yes} + \#\text{no}} = \frac{5}{15} = 0.333$$


Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje adaptativo con tablas de desvanecimiento

- Smoker?=yes
- Fading factor(s) = 0.5
- $\#(\text{Smoker}=\text{yes}) = \text{factor} * \#(\text{yes-previos}) + 1 = 0.5 * 10 + 1 = 6$
- $\#(\text{Smoker}=\text{no}) = \text{factor} * \#(\text{no-previos}) + 1 = 0.5 * 5 + 1 = 2.5$
- $\#(\text{experiencias}) = 6 + 2.5 = 8.5$
- $P(\text{Smoker}=\text{yes}) = \frac{6}{8.5} = 0.7059$
- $P(\text{Smoker}=\text{no}) = \frac{2.5}{8.5} = 0.2941$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje estructural



- No puede ser solucionado ajustando los parámetros
- Suposiciones erróneas acerca del dominio
- Aumenta el número de parámetros a ser estimados
- Suposiciones erróneas acerca del dominio

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Aprendizaje estructural

- Search and Score
 - Métrica de puntuación (Score)
 - Mide la calidad de la estructura gráfica
 - Se utiliza para decidir cual es la mejor solución
 - Algoritmo de búsqueda
 - Selecciona un pequeño subconjunto de las posibles redes que tengan una calidad alta
 - Se selecciona la “mejor”

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Basado en optimizaciones

Definir una función que evalúe qué tan bien se asemeja el modelo a los datos



Buscar una estructura que maximice esa función

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje estructural

- Tests de independencia
 - Obtienen las dependencias condicionales y las independencias utilizando tests de independencias entre triplas de variables
 - Por ejemplo tests estadísticos

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo K2

- Score and Search
- Búsqueda Greedy
- Muy eficiente
- Asume que las variables están ordenadas
- Comienza con una red sin arcos
- En cada iteración, para cada variable X_i , el nodo cuyo orden es previo a X_i y que incrementa la calidad de la red se agrega a $\text{Pa}(X_i)$
- Se repite el proceso hasta que
 - No hay incremento en la calidad de la red
 - Se llega a una red completa
- La cantidad de padres puede limitarse

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo B

- Score and Search
- No requiere un ordenamiento previo de las variables
 - Controlar ciclos
- Comienza con un conjunto vacío de padres
- En cada iteración agrega un arco tal que
 - No produce ciclos
 - Maximiza la calidad de la red
- El proceso se detiene cuando
 - No se incrementa la calidad de la red, o
 - Se llega a una red completa

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

- Tests de Independencia
- Dos fases
 - Construcción del esqueleto
 - Encontrar las direcciones de los arcos mediante tests de independencia
 - Orientar el resto de los arcos sin producir ciclos

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

- Construcción del esqueleto
 - Comienza con un grafo no dirigido totalmente conectado
 - Mediante tests de independencia va eliminando arcos que no cumplen la siguiente condición:
 - Dos nodos X e Y están conectados si y sólo si no existe un subconjunto S_{xy} del conjunto de vértices V tal que $I(X,Y|S_{xy})$ sea verdadero

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

Comienza con un grafo completo no dirigido g_p

$i = 0$

Repeat

For each $X \in V$

For each $Y \in \text{ADJ}_X$

Determinar si existe $S \subseteq \text{ADJ}_X - \{Y\}$ con $|S| = i$ y $I(X,Y|S)$

Si este conjunto existe







$S_{XY} = S$







Eliminar el arco $X-Y$

$i = i+1$

Until $|\text{ADJ}_X| \leq i; \forall X$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN





Algoritmo PC

No hay nodos con más de 3 adyacentes

$S_{XY}=\{\}$
 $S_{XW}=\{\}$
 $S_{ZW}=\{Y\}$
 $S_{XT}=\{Z,W\}$
 $S_{YT}=\{Z,W\}$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

- Encontrar las direcciones de los arcos mediante tests de independencia (tomando las variables de a tres)
- Para cada variable Z con dos adyacentes X e Y comprueba que no Z no esté en S_{XY} para conectar a X e Y como padres de Z

$Y \text{ --- } Z \text{ --- } X$
 $Y \text{ --- } Z \text{ --- } X$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

$Z \notin S_{XY}$

$S_{XY}=\{\}$
 $S_{XW}=\{\}$
 $S_{ZW}=\{Y\}$
 $S_{XT}=\{Z,W\}$
 $S_{YT}=\{Z,W\}$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

$Z \notin S_{XY}$

$S_{XY}=\{\}$
 $S_{XW}=\{\}$
 $S_{ZW}=\{Y\}$
 $S_{XT}=\{Z,W\}$
 $S_{YT}=\{Z,W\}$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

$T \notin S_{ZW}$

$S_{XY}=\{\}$
 $S_{XW}=\{\}$
 $S_{ZW}=\{Y\}$
 $S_{XT}=\{Z,W\}$
 $S_{YT}=\{Z,W\}$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo PC

$T \notin S_{ZW}$

$S_{XY}=\{\}$
 $S_{XW}=\{\}$
 $S_{ZW}=\{Y\}$
 $S_{XT}=\{Z,W\}$
 $S_{YT}=\{Z,W\}$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN



Herramientas

- Hugin: http://www.hugin.com/Products_Services/Products/Demo/
- Bayesware: <http://www.bayesware.com/>
- JavaBayes: <http://www-2.cs.cmu.edu/~javabayes/>
- Página de Finn Jensen: <http://www.cs.aau.dk/~fvj>

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Modelos de Markov

Agenda

- Introducción
- Redes de Bayes
- Modelos de Markov
 - Introducción
 - Cadenas de Markov
 - Modelos Ocultos de Markov

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Introducción

- Modelar dependencias entre símbolos de una secuencia
 - Temporales:
 - En reconocimiento del habla: fonemas en una palabra, palabras en una oración (reconocimiento sintáctico)
 - Espaciales
 - Reconocimiento de escritura
 - Secuencias de genes

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Procesos aleatorios de Markov

- Una secuencia aleatoria tiene la propiedad de Markov si su distribución de probabilidades está determinada únicamente por el estado actual. Un proceso aleatorio que cumple con esta propiedad se llama un proceso aleatorio de Markov
- Cuando los estados son observables → cadenas de Markov
- Cuando los estados no son observables → modelos ocultos de Markov (HMM, hidden Markov models)

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Regla de Bayes

$$P(q_t, q_{t-1}, \dots, q_1) = P(q_t | q_{t-1}, \dots, q_1) P(q_{t-1}, \dots, q_1)$$

$$P(q_t, q_{t-1}, \dots, q_1) = P(q_t | q_{t-1}, \dots, q_1) P(q_{t-1} | q_{t-2}, \dots, q_1) P(q_{t-2}, \dots, q_1)$$

$$P(q_t, q_{t-1}, \dots, q_1) = P(q_1) \prod_{i=2}^t P(q_i | q_{i-1}, \dots, q_1)$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Propiedad de Markov

$$P(q_i | q_{i-1}, \dots, q_1) = P(q_i | q_{i-1}) \text{ for } i > 1$$

$$P(q_t, q_{t-1}, \dots, q_1) = P(q_1) \prod_{i=2}^t P(q_i | q_{i-1}) = P(q_1) P(q_2 | q_1) \dots P(q_t | q_{t-1})$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Cadenas de Markov

- Pueden verse como un grafo de transición de estados con probabilidades en sus arcos
- Ejemplo: Generación de Texto Aleatorio
 - Un nodo por cada letra única observada
 - Si luego de la letra X observo la letra Y agrego un arco de X a Y
 - Si el arco ya existe incremento la cantidad de observaciones asociada al arco

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov


TOTAL




Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov

TOTAL



Dr. Marcelo G. Armentano - ISISTAN - UNICEN



Cadenas de Markov

TOTAL

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov

TOTAL

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov

- Texto aleatorio generado a partir de un modelo entrenado con el primer capítulo de "100 años de soledad" de Gabriel García Marquez

Mapl idoca **Uno** domen quespiate mé s abrdiaton quadelaros **del** y en ióra púllade y añosar só. Ar e Pon s tóntun llose fase co **tus** pe fo aciguela tr **de** paquros losintun. oceton deros **picaras** ro. pigeltexpa Arrcón asadosen ca hiracugidend madel cos **pe**lo ca hamuy cuncte prera letrapuina venco sosué gifuas y estiigidire y ple, peno do dociemano y den matrones s Arsélades, lelanelo lacides Jombidorentió lla caquétrotran **de** ciechitevo, pa e tró ulega teilizaban riaden zopen desellaundo u ca tioroserar vorasun para **en fue**, dempa teresen y umus mpio y **sedes** s s ezordel rugexhas darmabió.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de orden N

- Extensión a las cadenas de Markov en las que cada estados representa una secuencia de N observaciones consecutivas
- N-gramas

ch se observa 100 veces, de las cuales...

	Ocurrencias
che	60
chi	25
cha	10
cho	5

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de orden N

- N=2

MISSISSIPPI

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de orden N

- N=3

MISSISSIPPI

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de orden N

- N=1
 - Modelo fiel a las frecuencias de cada par de letras
 - No representa bien el lenguaje natural

Mapl idoca Uno domen **quespiate** mé s abrdiaton **quadelaros** del y en ióra púllade y añosar só. Ar e Pon s tóntun llose fase co tus pe fo aciguela tr de **paquros** losintun. oceton deros picaras ro. pigeltexpa Arrcón asadosen ca hirácuigidend madel cos pelo ca hamuy cuncte prera letrapuina venco sosué gifutas y estiogidire y ple, peno do dociemano y den matrones s Arsélades, lelanelo lacides Jombidorentió lla **caqué**trotan de ciechitevo, pa e tró ulega teilizaban riaden zopen desellaundo u ca tioroserar vorasun plara en fue, dempa teresen y umus mpio y sedes s s ezordel rugexhas darmabió.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de Orden N

- Texto aleatorio generado N=2

Muca donios y **hombre** llas res pla plambregrimanteó **el la** sió entu de Salemo **fue** unción co crión. **Tendía en** sula ta chicalque **le siez** blena **que tras**, senterosagareto. —gruel res entorasanesbazuerasabe pán, enda **con de** in inagercamieropito **don** cuareciór siblimena tero **en jó te**. Fuedo paresegua pespurantespuen **dos** porodad **de la que** caba quentra denabrecestimnotescuyó quel mor losé Acturo, pen for **es ella** guanos mitadrraratientón, condía **la** allado quen **se** logó **la** ba laritiva triblesala **sólos** habalcabiempore ere gría to borse allas laciasímisible **por** pocaza **los**, so **ola la niños** cuaro **él** y lar espiendismo añonetro **una**, que cad fuerofocieres resa combrepuros parsu misiblocerma anoceraya elos no **a** y ejó desta **una** tión.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de Orden N

- Texto aleatorio generado N=3

Muchetextremecitano **conveniencia**. **Cuando por** acora pre hablancie el rudiente **el** pusierantado **poblado pago** y **aumentar animaginación**, aza des, examillos **más** gígaciera suellelvó **los que** inte **la** viajes rayos imales **hacedor** y **el término** puaes siles expedas mocha **que la** tanos **ser en que** vez lles, **la como la más** pase lo únicos, romera lado José Arcadiosas, **antes, al** realejo **en que de** dejó todidos tre distilado **infinito** desco, **a le se para ver** bolada alquída.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de Orden N

- Texto aleatorio generado N=4

Muchos y salambió **un chaleco de** había **burla como** el pasó **la** resto de aban su **fue ser prendedor** condo **una buena de la casa** quimisterios, José Arcadio Buendía, **sino** esentó **como un en** aquel **tambor, quedó** recuerdo **de un fugitivo en que en que** sierrar **los** metalejos a puestaban **de una** tersas, y **el mundo sino** consolas, y **veían** desar **a la casa, cuyos sin comer Aureliano, conjuro de** el esperso **de** piedras.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de orden N

- N = 3-4
 - Comienzan a aparecer palabras más reconocibles
 - Palabras de muchas letras aparecen frecuentemente "pegadas" a otras palabras
- Cuanto más extenso es el texto de entrenamiento, más variedad habrá en la salida

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de Orden N

- Entrenamiento con palabras completas (N=1)
- Texto generado:

Se había que construyó trampas y sus iniciales encima con una insolación por mares incógnitos, visitar territorios más emprendedor que se hundían en las maravillas del mundo. Era una explicación inmediata, José Arcadio Buendía, la resonancia hueca de helechos y entonces una truculenta demostración con un áspero sabor de fusilamiento, el interior, y tambores y a prepararse para llevárselos a palmo a conocerlo, mantuvo puesta por los burros." Así fue desde hacía mucho tiempo, porque el mundo se asomaba al caramelo vulgar que un pánico cuando llegó la judía.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Cadenas de Markov de Orden N

- Entrenamiento con palabras completas (N=4)
- Texto generado:

Consideraba como una burla de su travieso destino haber buscado el mar sin encontrarlo, al precio de sacrificios y penalidades sin cuento, y haberlo encontrado entonces sin buscarlo, atravesado en su camino como un obstáculo insalvable.

Úrsula no volvió a acordarse de la intensidad de esa mirada hasta un día en que el pequeño Aureliano, a la edad de tres años, entró a la cocina en el momento en que ella retiraba del fogón y ponía en la mesa una olla de caldo hirviendo.

Aquel olor mordiente quedaría para siempre en su memoria, vinculado al recuerdo de Melquíades.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Modelos de Markov

- Conjunto de estados: $\{s_1, s_2, \dots, s_N\}$
- El proceso se mueve de un estado a otro generando una secuencia de estados $s_{i1}, s_{i2}, \dots, s_{ik}, \dots$
- Propiedad de Markov: la probabilidad de cada estado siguiente depende sólo del estado previo

$$P(s_{ik} | s_{i1}, s_{i2}, \dots, s_{ik-1}) = P(s_{ik} | s_{ik-1})$$

- Para definir un modelo de Markov deben especificarse las siguientes probabilidades:

$$\pi_i = P(s_i)$$


$$a_{ij} = P(s_i | s_j)$$

Probabilidad del estado inicial

Probabilidad de transición de estados

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo de modelo de Markov



- Dos posibles estados: 'Lluvioso' y 'Seco'.
- Probabilidades de Transición:

$$P(\text{'Lluvioso'} | \text{'Lluvioso'}) = 0.3,$$

$$P(\text{'Seco'} | \text{'Lluvioso'}) = 0.7,$$

$$P(\text{'Lluvioso'} | \text{'Seco'}) = 0.2,$$

$$P(\text{'Seco'} | \text{'Seco'}) = 0.8$$

- Probabilidades iniciales:

$$P(\text{'Lluvioso'}) = 0.4$$

$$P(\text{'Seco'}) = 0.6$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Probabilidad de una secuencia

- Por la propiedad de Markov:

$$\begin{aligned} P(s_{i1}, s_{i2}, \dots, s_{ik}) &= P(s_{ik} | s_{i1}, s_{i2}, \dots, s_{ik-1}) P(s_{i1}, s_{i2}, \dots, s_{ik-1}) \\ &= P(s_{ik} | s_{ik-1}) P(s_{i1}, s_{i2}, \dots, s_{ik-1}) = \dots \\ &= P(s_{ik} | s_{ik-1}) P(s_{ik-1} | s_{ik-2}) \dots P(s_{i2} | s_{i1}) P(s_{i1}) \end{aligned}$$

$$\begin{aligned} P(\{\text{'Seco'}, \text{'Seco'}, \text{'Lluvioso'}, \text{'Lluvioso'}\}) &= \\ P(\text{'Lluvioso'} | \text{'Lluvioso'}) P(\text{'Lluvioso'} | \text{'Seco'}) &= \\ P(\text{'Seco'} | \text{'Seco'}) P(\text{'Seco'}) &= \\ 0.3 * 0.2 * 0.8 * 0.6 &= 0.0288 \end{aligned}$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Underflow

- El producto de muchas probabilidades entre 0 y 1 puede resultar en underflow
- Dado que $\log(xy) = \log(x) + \log(y)$, es mejor realizar la suma del logaritmo de las probabilidades que multiplicarlas
- El modelo con el mayor puntaje final de probabilidad logarítmica sigue siendo la más probable

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Hipótesis del máximo a posteriori


$$\begin{aligned} h_{MAP} &\equiv \arg \max_{h \in H} P(h | D) \\ &= \arg \max_{h \in H} \frac{P(D | h) P(h)}{P(D)} \\ &= \arg \max_{h \in H} P(D | h) P(h) \end{aligned}$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Modelos Ocultos de Markov (HMM)

- Conjunto de estados: $\{s_1, s_2, \dots, s_N\}$
- El proceso de mueve de un estado a otro generando una secuencia de estados: $s_{i1}, s_{i2}, \dots, s_{ik}, \dots$
- Propiedad de Markov: La probabilidad de cada estado depende solo del estado actual $P(s_{ik} | s_{i1}, s_{i2}, \dots, s_{ik-1}) = P(s_{ik} | s_{ik-1})$
- Los estados **no son visibles**, pero cada estado genera aleatoriamente una de las posibles observaciones (**estados visibles**) $\{v_1, v_2, \dots, v_M\}$
- Para definir un modelo oculto de Markov, se deben especificar las siguientes probabilidades:
 - Matriz de probabilidades transición $A=(a_{ij})$, $a_{ij} = P(s_j | s_i)$
 - Matriz de probabilidades de observación $B=(b_i(v_m))$, $b_i(v_m) = P(v_m | s_i)$
 - Vector de probabilidades iniciales $\pi=(\pi_i)$, $\pi_i = P(s_i)$
- Los modelos quedan definidos por la tripla $M=(A, B, \pi)$


Dr. Marcelo G. Armentano - ISISTAN - UNICEN



Ejemplo de HMM

- Dos estados correspondientes a la presión atmosférica:
 - 'Alta' y 'Baja'
- Dos posibles observaciones:
 - 'Lluvioso' y 'Seco'.
- Probabilidades de Transición:
 - $P('Baja'|'Baja')=0.3$, $P('Alta'|'Baja')=0.7$, $P('Baja'|'Alta')=0.2$, $P('Alta'|'Alta')=0.8$
- Probabilidades de Observación:
 - $P('Lluvioso'|'Baja')=0.6$, $P('Seco'|'Baja')=0.4$, $P('Lluvioso'|'Alta')=0.4$, $P('Seco'|'Alta')=0.3$.
- Probabilidades iniciales:
 - $P('Baja')=0.4$, $P('Alta')=0.6$.


Dr. Marcelo G. Armentano - ISISTAN - UNICEN



Ejemplo de HMM

	Empapado	Húmedo	Casi seco	Seco
Sol	0,60	0,20	0,15	0,05
Nubes	0,25	0,25	0,25	0,25
Lluvia	0,05	0,10	0,35	0,50

Dr. Marcelo G. Armentano - ISISTAN - UNICEN



Representación de una Red de Markov

i	$P(q_{t+1}=s_1 q_t=s_i)$	$P(q_{t+1}=s_2 q_t=s_i)$	$P(q_{t+1}=s_j q_t=s_i)$	$P(q_{t+1}=s_N q_t=s_i)$
1	a_{11}	a_{12}	...	a_{1j}
2	a_{21}	a_{22}	...	a_{2j}
3	a_{31}	a_{32}	...	a_{3j}
...				
i	a_{i1}	a_{i2}	...	a_{ij}
...				
N	a_{N1}	a_{N2}	...	a_{Nj}
				a_{NN}

Todas estas tablas son iguales

$a_{ij} = P(q_{t+1}=s_j | q_t=s_i)$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Representación de una Red de Markov

i	$P(O_t=1 q_t=s_i)$	$P(O_t=2 q_t=s_i)$	$P(O_t=j q_t=s_i)$	$P(O_t=N q_t=s_i)$
1	$b_1(1)$	$b_1(2)$...	$b_1(j)$
2	$b_2(1)$	$b_2(2)$...	$b_2(j)$
3	$b_3(1)$	$b_3(2)$...	$b_3(j)$
...				
i	$b_i(1)$	$b_i(2)$...	$b_i(j)$
...				
N	$b_N(1)$	$b_N(2)$...	$b_N(j)$
				$b_N(N)$

Todas estas tablas son iguales

$b_i(j) = P(O_t=j | q_t=s_i)$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Representación de un HMM como un enrejado

Observaciones O_1 O_k O_{k+1} O_K

Tiempo 1 k k+1 K

Ejemplo: Casino tramposo

Un casino tiene dos dados:

- Dado "justo"
 - $P(1) = P(2) = P(3) = P(5) = P(6) = 1/6$
- Dado cargado
 - $P(1) = P(2) = P(3) = P(4) = P(5) = 1/10$
 - $P(6) = 1/2$

El casino alterna entre el dado justo y el cargado una vez cada 20 turnos

Problemas a resolver con HMM

- Evaluación
 - Dado un HMM $M=(A, B, \pi)$ y una secuencia de observaciones $O=o_1, o_2, \dots, o_K$, calcular la probabilidad de que el modelo M haya generado la secuencia O

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Evaluación

Dada una secuencia de tiradas del casino

1245526462146146136661664661636616366163616515615146123562344

¿Cuan probable es esta secuencia, dado nuestro modelo de como opera el casino?

Este es el problema de **EVALUACIÓN** en HMMs

Problemas a resolver con HMM

- Decodificación o inferencia
 - Dado un HMM $M=(A, B, \pi)$ y una secuencia de observaciones $O=o_1, o_2, \dots, o_K$, calcular la secuencia de estados ocultos S_i que más probablemente produjo la secuencia de observaciones O

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Decodificación

Dada una secuencia de tiradas del casino

1245526462146146136136661664661636616366163616515615115146123562344

¿Que partes de la secuencia fueron generadas por el dado cargado y cuales por el dado justo?

Este es el problema de **DECODIFICACIÓN** en HMMs

Problemas a resolver con HMM

- Aprendizaje
 - Dado un conjunto de secuencias de observaciones de entrenamiento $O=o_1, o_2, \dots, o_K$, y la estructura general de HMM (cantidad de estados ocultos y cantidad de estados visibles), determinar los parámetros del HMM $M=(A, B, \pi)$ que mejor se ajustan a los datos de entrenamiento.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje


Dada una secuencia de tiradas del casino

1245526462146146136136661664661636616366163616515615115146123562344

¿Cómo está cargado el dado cargado? ¿Cada cuanto cambia el casino entre el dado cargado y el justo?

Este es el problema de **APRENDIZAJE** en HMMs

El HMM del casino tramposo




- $P(1|Justo) = 1/6$
- $P(2|Justo) = 1/6$
- $P(3|Justo) = 1/6$
- $P(4|Justo) = 1/6$
- $P(5|Justo) = 1/6$
- $P(6|Justo) = 1/6$

- $P(1|Cargado) = 1/10$
- $P(2|Cargado) = 1/10$
- $P(3|Cargado) = 1/10$
- $P(4|Cargado) = 1/10$
- $P(5|Cargado) = 1/10$
- $P(6|Cargado) = 1/2$

Ejemplo: reconocimiento de palabras

- Se asume que los caracteres están separados
- El reconocedor de caracteres da como salida la probabilidad de que una imagen corresponda a un caracter particular: $P(\text{caracter}|\text{imagen})$.



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo: reconocimiento de palabras

- Estados Ocultos del HMM: caracteres
- Estados Observables: imágenes de caracteres v_α
- Probabilidades de Observación:

$$B = (b_i(v_\alpha)) = (P(v_\alpha | s_i))$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo: reconocimiento de palabras

- Si se conoce el diccionario, es posible construir un modelo individual para cada palabra

- Problema de **evaluación**: reconocer la palabra en una imagen es equivalente a evaluar un conjunto de modelos.

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Ejemplo: reconocimiento de palabras

- Podemos construir un HMM para **todas** las palabras
- Estados ocultos: los caracteres de las palabras
- Probabilidades de transición: calculadas a partir de modelos del lenguaje
- Observaciones y probabilidades de observación iguales al ejemplo anterior

- Problema de **decodificación**: encontrar la secuencia de estados ocultos que más probablemente generaron la imagen

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Problemas a resolver con HMM

- Dada una secuencia de observaciones O_1, O_2, \dots, O_T

Problema	Algoritmo	Complejidad
Evaluación: Calcular $P(O M)$	Forward-Backward	$(TN)^2$
Inferencia: Calcular $Q^* = \text{argmax}_Q P(Q O, M)$	Viterbi Decoding	$(TN)^2$
Aprendizaje: Calcular $M^* = \text{argmax}_M P(O M)$	Baum-Welch (EM)	$(TN)^2$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Forward

Obs:

	Seco	Húmedo	Empapado
Sol	Sol	Sol	Sol
Nubes	Nubes	Nubes	Nubes
Lluvia	Lluvia	Lluvia	Lluvia

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Forward

- $\Pr(\text{Seco, Húmedo, Empapado} | M) =$
 $\Pr(\text{seco, húmedo, empapado} | \text{sol, sol, sol}) +$
 $\Pr(\text{seco, húmedo, empapado} | \text{sol, nubes, sol}) +$
 \dots
 $\Pr(\text{seco, húmedo, empapado} | \text{lluvia, lluvia, lluvia})$

$3^3 = 27$ cálculos

¡¡Muy Costoso!!

Dr. Marcelo G. Armentano - ISISTAN - UNICEN


Algoritmo Backward

- Inicialización:

$$\beta_T(j) = 1$$
- Cálculo:

$$\beta_t(i) = \sum_{j=1}^N \beta_{t+1}(j) a_{ij} b_j(o_{t+1})$$
- Finalización:

$$p(O|\lambda) = \sum_{i=1}^N \pi(i) b_i(o_1) \beta_1(i) \quad t = T-1, \dots, 1$$



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Problemas a resolver con HMM

- Dada una secuencia de observaciones O_1, O_2, \dots, O_T

Problema	Algoritmo	Complejidad
Evaluación: Calcular $P(O M)$	Forward- Backward	$(TN)^2$
Inferencia: Calcular $Q^* = \text{argmax}_Q P(Q O,M)$	Viterbi Decoding	$(TN)^2$
Aprendizaje: Calcular $M^* = \text{argmax}_M P(O M)$	Baum-Welch (EM)	$(TN)^2$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- Encontrar la secuencia más probable de estados ocultos, dada una secuencia de observaciones
- Ejemplo: etiquetar palabras en una oración con su función sintáctica

¿Estados observables? ¿Estados ocultos?


NS NP OD

Juan come naranjas

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- Probabilidad parcial δ de alcanzar un estado intermedio particular en el entramado
- δ representa la probabilidad del camino más probable a un estado
- Para cada estado final hay un camino más probable a ese estado



Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- $\delta(i,t)$ es la máxima probabilidad de todas las secuencias que terminan en el estado i en el tiempo t
- En $t=T$ tenemos las mejores probabilidades parciales y los mejores caminos parciales.
- El mejor camino global a T es el que lleva al estado con la mayor probabilidad

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- En $t=1$

$$\delta(1,i) = \pi(i) \cdot b_i(o_1)$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- En $t > 1$

$T < t-1$ $t-1$ t

$$\Pr(x \text{ en } T=t) = \max_{i=A,B,C} \Pr(i \text{ en } T=t-1) \Pr(X|i) \Pr(O_t|X)$$

$$\delta(t, i) = \max_j (\delta(t-1, j) \cdot a_{j,i}) \cdot b_i(o_t)$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

- En cada tiempo t , recordamos el estado j que generó $\delta(t, i)$

$$\phi(t, i) = \max_j \delta(t-1, j) \cdot a_{j,i}$$

- Se reconstruye el camino utilizando los punteros ϕ hasta el tiempo $t=1$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo de Viterbi

$$P^* = \max_{1 \leq i \leq N} \delta_T(i)$$

P^* da la probabilidad de los mejores los estados

$$q_T^* = \arg \max_{1 \leq i \leq N} \delta_T(i)$$

q_T^* es la secuencia de estados óptima
 $(Q^* = \{q_1^*, q_2^*, \dots, q_T^*\})$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Problemas a resolver con HMM

- Dada una secuencia de observaciones O_1, O_2, \dots, O_T

Problema	Algoritmo	Complejidad
Evaluación: Calcular $P(O M)$	ForwardBackward	$(TN)^2$
Inferencia: Calcular $Q^* = \arg \max_Q P(Q O, M)$	Viterbi Decoding	$(TN)^2$
Aprendizaje: Calcular $M^* = \arg \max_M P(O M)$	Baum-Welch (EM)	$(TN)^2$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje

- Dada un conjunto de secuencias de observaciones $O=O_1, O_2, \dots, O_K$ y la estructura general del HMM (cantidad de estados ocultos y visibles), determinar los parámetros del modelo $M=(A, B, \pi)$ que mejor se ajustan a los datos de entrenamiento, es decir, que maximice $P(O | M)$.
- Se utiliza el algoritmo de maximización de la esperanza para encontrar un máximo local de $P(O | M)$: **algoritmo Baum-Welch**

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Aprendizaje

- Si los datos de entrenamiento tienen información acerca de la secuencia de estados ocultos, los parámetros se estiman como:

$$a_{i,j} = P(s_i | s_j) = \frac{\# \text{transiciones } s_j \rightarrow s_i}{\# \text{transiciones } s_j \rightarrow x}$$

$$b_i(o_m) = P(o_m | s_i) = \frac{\# \text{observaciones de } o_m \text{ en } s_i}{\# \text{veces } s_i}$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Baum-Welch

- Idea general:

$$a_{i,j} = P(s_i | s_j) = \frac{\text{\#esperado de transiciones } s_j \rightarrow s_i}{\text{\#esperado de transiciones } s_j \rightarrow x}$$

$$b_i(o_m) = P(o_m | s_i) = \frac{\text{\#esperado de observaciones de } o_m \text{ en } s_i}{\text{\#esperado de veces } s_i}$$

$$\pi_t = P(s_t) = \text{\#esperado de veces en } s_i \text{ para } t=1$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Baum-Welch

$$\xi_t(i,j) = P(q_t = s_i, q_{t+1} = s_j | o_1, o_2, \dots, o_T)$$

$$\xi_t(i,j) = \frac{P(q_t = s_i, q_{t+1} = s_j, o_1, o_2, \dots, o_T)}{P(o_1, o_2, \dots, o_T)} =$$

$$\frac{P(q_t = s_i, o_1, o_2, \dots, o_t) a_{ij} b_j(o_{t+1}) P(o_{t+2}, \dots, o_T | q_{t+1} = s_j)}{P(o_1, o_2, \dots, o_T)} =$$

$$\frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_i \sum_j \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)} = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_i \alpha_t(i) \beta_{t+1}(i)}$$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Baum-Welch

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Baum-Welch

- Definimos $\gamma_t(i)$ como la probabilidad de estar en el estado i en el tiempo t dadas las observaciones

$$\gamma_t(i) = P(q_t = s_i | o_1, o_2, \dots, o_T) \quad \gamma_t(i) = \sum_{j=1}^N \xi_t(i, j)$$

- $\sum_t \gamma_t(i)$ - cantidad esperada de veces que visito el estado i
- $\sum_t \xi_t(i, j)$ - cantidad esperada de transiciones $i \rightarrow j$

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Algoritmo Baum-Welch

- $\hat{\pi} = \gamma_1(i)$ la frecuencia esperada del estado i en $t=1$
- $\hat{a}_{ij} = \frac{\sum_t \xi_t(i, j)}{\sum_t \gamma_t(i)}$ número esperado de transiciones desde el estado i al estado j sobre la cantidad esperada de transiciones desde el estado i
- $\hat{b}_{j(o_k)} = \frac{\sum_{t, o_t = o_k} \gamma_t(j)}{\sum_t \gamma_t(j)}$ cantidad de veces que se estuvo en el estado j observando el símbolo k sobre la cantidad de veces que se estuvo en el estado j

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

Bibliografía

- Bayesian Networks and Decision Graphs - Finn V. Jensen and Thomas D. Nielsen - Springer Verlag - Second Edition - 2007
- A tutorial on hidden Markov models and selected applications in speech recognition - Lawrence R. Rabiner - Proceedings of the IEEE, Vol. 77, N°2, pp. 257-286 - 1989

Dr. Marcelo G. Armentano - ISISTAN - UNICEN

