

## REDES BAYESIANAS NORMALES (RBN)

En una red bayesiana normal, las variables  $X$  son normales  $N(\mu, \Sigma)$  con función de densidad:

$$(2\pi)^{-n/2} |\Sigma|^{-1/2} \exp \left\{ -1/2 (x - \mu)^T \Sigma^{-1} (x - \mu) \right\},$$

donde  $\mu$  es el vector  $n$ -dimensional de medias,  $\Sigma$  es la matriz  $n \times n$  de covarianzas,  $|\Sigma|$  es el determinante de  $\Sigma$ , y  $\mu^T$  es la traspuesta de  $\mu$ .

Como en toda red Bayesiana, la función de densidad conjunta puede escribirse como producto de las funciones de probabilidad condicionadas:

$$f(x_i | \pi_i) \sim N \left( \mu_i + \sum_{j=1}^{i-1} \beta_{ij} (x_j - \mu_j), v_i \right), \quad (1)$$

donde  $\beta_{ij}$  es el coeficiente de regresión de  $X_j$  en la regresión de  $X_i$  sobre los padres,  $\Pi_i$ , de  $X_i$  y

$$v_i = \Sigma_i - \Sigma_{i\Pi_i} \Sigma_{\Pi_i}^{-1} \Sigma_{i\Pi_i}^T$$

es la varianza condicionada de  $X_i$ , dado  $\Pi_i = \pi_i$ , donde  $\Sigma_i$  es la varianza incondicional de  $X_i$ ,  $\Sigma_{i\Pi_i}$  son las covarianzas entre  $X_i$  y las variables de  $\Pi_i$ , y  $\Sigma_{\Pi_i}$  es la matriz de covarianzas de  $\Pi_i$ .

## REDES BAYESIANAS NORMALES

Obsérvese que  $\beta_{ij}$  mide el grado de relación existente entre las variables  $X_i$  y  $X_j$ . Si  $\beta_{ij} = 0$ , entonces  $X_j$  no será un padre de  $X_i$ .

Una red Bayesiana normal depende de los parámetros  $\{\mu_1, \dots, \mu_n\}$ ,  $\{v_1, \dots, v_n\}$ , y  $\{\beta_{ij} \mid j < i\}$ .

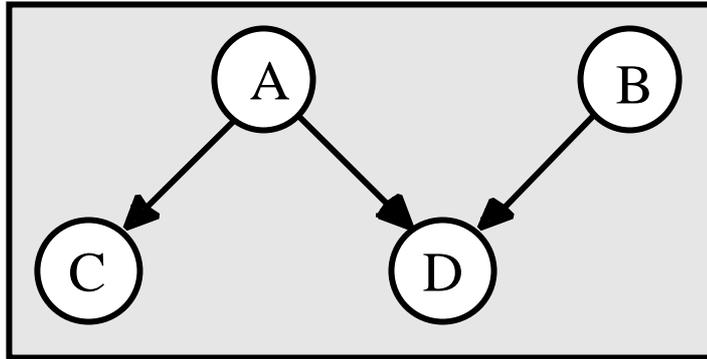
Una función de probabilidad normal puede definirse de forma alternativa mediante su vector de medias  $\mu$  y su matriz de precisión  $W = \Sigma^{-1}$ . La transformación recursiva para pasar de  $\{v_1, \dots, v_n\}$  y  $\{\beta_{ij} : j < i\}$  a  $W$  es:

$$W(i+1) = \begin{pmatrix} W(i) + \frac{\beta_{i+1}\beta_{i+1}^T}{v_{i+1}} & \frac{-\beta_{i+1}}{v_{i+1}} \\ \frac{-\beta_{i+1}^T}{v_{i+1}} & \frac{1}{v_{i+1}} \end{pmatrix}, \quad (2)$$

donde  $W(1) = 1/v_1$ ,  $W(i)$  es la matriz superior izquierda  $i \times i$  de  $W$  y  $\beta_i$  es el vector columna  $\{\beta_{ij} : j < i\}$

Por tanto, se tienen dos representaciones alternativas de la función de probabilidad de una red Bayesiana normal.

## REDES BAYESIANAS NORMALES



Considérese la red bayesiana de la figura sobre  $\{A, B, C, D\}$  con  $f(a, b, c, d) \sim N(\mu, \Sigma)$ , que puede factorizarse como:

$$f(a, b, c, d) = f(a)f(b)f(c|a)f(d|a, b), \quad (3)$$

donde

$$f(a) \sim N(\mu_A, v_A),$$

$$f(b) \sim N(\mu_B, v_B),$$

$$f(c|a) \sim N(\mu_C + \beta_{CA}(a - \mu_A), v_C),$$

$$f(d|a, b) \sim N(\mu_D + \beta_{DA}(a - \mu_A) + \beta_{DB}(b - \mu_B), v_D).$$

Los parámetros de esta representación son

$$\{\mu_A, \mu_B, \mu_C, \mu_D\},$$

$$\{v_A, v_B, v_C, v_D\}, y$$

$$\{\beta_{CA}, \beta_{DA}, \beta_{DB}\}.$$

Una representación alternativa la da  $W$ :

$$\begin{pmatrix} \frac{1}{v_A} + \frac{\beta_{CA}^2}{v_C} + \frac{\beta_{DA}^2}{v_D} & \frac{\beta_{DA}\beta_{DB}}{v_D} & -\frac{\beta_{CA}}{v_C} & -\frac{\beta_{DA}}{v_D} \\ \frac{\beta_{DA}\beta_{DB}}{v_D} & \frac{1}{v_B} + \frac{\beta_{DB}^2}{v_D} & 0 & -\frac{\beta_{DB}}{v_D} \\ -\frac{\beta_{CA}}{v_C} & 0 & \frac{1}{v_C} & 0 \\ -\frac{\beta_{DA}}{v_D} & -\frac{\beta_{DB}}{v_D} & 0 & \frac{1}{v_D} \end{pmatrix}.$$

La matriz de covarianzas resulta:

$$\begin{pmatrix} v_A & 0 & \beta_{CA}v_A & \beta_{DA}v_A \\ 0 & v_B & 0 & \beta_{DB}v_B \\ \beta_{CA}v_A & 0 & \beta_{CA}^2v_A + v_C & \beta_{CA}\beta_{DA}v_A \\ \beta_{DA}v_A & \beta_{DB}v_B & \beta_{CA}\beta_{DA}v_A & \beta_{DA}^2v_A + \beta_{DB}^2v_B + v_D \end{pmatrix}.$$

Considerando nulas las medias, uno las varianzas,  $\beta_{CA} = 1$ ,  $\beta_{DA} = 0.2$  y  $\beta_{DB} = 0.8$ , se tiene

$$\Sigma = \begin{pmatrix} 1.0 & 0.0 & 1.0 & 0.20 \\ 0.0 & 1.0 & 0.0 & 0.80 \\ 1.0 & 0.0 & 2.0 & 0.20 \\ 0.2 & 0.8 & 0.2 & 1.68 \end{pmatrix}. \quad (4)$$

**Teorema 1 Distribución normal multivariada.**

*Sean  $Y$  y  $Z$  dos conjuntos de variables aleatorias con función de distribución normal multivariada cuyo vector de medias y matriz de covarianzas son*

$$\mu = \begin{pmatrix} \mu_Y \\ \mu_Z \end{pmatrix} \quad \text{y} \quad \Sigma = \begin{pmatrix} \Sigma_{YY} & \Sigma_{YZ} \\ \Sigma_{ZY} & \Sigma_{ZZ} \end{pmatrix},$$

*donde  $\mu_Y$  y  $\Sigma_{YY}$  son el vector de medias y la matriz de covarianzas de  $Y$ ,  $\mu_Z$  y  $\Sigma_{ZZ}$  son el vector de medias y la matriz de covarianzas de  $Z$ , y  $\Sigma_{YZ}$  es la matriz de covarianzas de  $Y$  y  $Z$ . Entonces, la función de probabilidad condicionada de  $Y$  dado  $Z = z$  es una función normal multivariada con vector de medias  $\mu_{Y|Z=z}$  y matriz de covarianzas  $\Sigma_{Y|Z=z}$ , donde*

$$\mu_{Y|Z=z} = \mu_Y + \Sigma_{YZ}\Sigma_{ZZ}^{-1}(z - \mu_Z), \quad (5)$$

$$\Sigma_{Y|Z=z} = \Sigma_{YY} - \Sigma_{YZ}\Sigma_{ZZ}^{-1}\Sigma_{ZY}. \quad (6)$$

Es conveniente actualizar de uno en uno los nodos evidenciales.



Universidad  
de Cantabria

## PROPAGACION EXACTA EN REDES BAYESIANAS NORMALES Y MATHEMATICA

```
(* Definición de la función de probabilidad *)
M={0,0,0,0};
V={{1.0, 0.0, 1.0, 0.2},
   {0.0, 1.0, 0.0, 0.8},
   {1.0, 0.0, 2.0, 0.2},
   {0.2, 0.8, 0.2, 1.68}};
(* Nodos y evidencia *)
X={A,B,C,D};Ev={A,B,C};ev={1,3,2};
(* Actualización de M y V *)
NewM=Transpose[List[M]];
NewV=V;
For[k=1, k<=Length[Ev], k++,
  (* Posición del elemento i-ésimo de E[[k]] en X *)
  i=Position[X,Ev[[k]]][[1,1]];
  My>Delete[NewM,i];
  Mz=NewM[[i,1]];
  Vy=Transpose>Delete[Transpose>Delete[NewV,i],i];
  Vz=NewV[[i,i]];
  Vyz=Transpose[List>Delete[NewV[[i]],i]];
  NewM=My+(1/Vz)*(ev[[k]]-Mz)*Vyz;
  NewV=Vy-(1/Vz)*Vyz.Transpose[Vyz];
  (* Eliminar el elemento i-ésimo *)
  X>Delete[X,i];
  (* Imprimir los resultados *)
  Print["Iteracion = ",k];Print["Nodos restantes = ",X];
  Print["M = ",Together[NewM]];
  Print["V = ",Together[NewV]];
  Print["-----"];]
```

**Bayesian Networks: Simulation**

**Teorema 2** *Considérese una red Bayesiana normal definida en  $X = \{X_1, \dots, X_n\}$  con vector de media  $\mu$  y matriz de covarianzas  $\Sigma$ . Particionemos  $X$ ,  $\mu$  y  $\Sigma$  en la forma  $X = \{Y, Z\}$ ,*

$$\mu = \begin{pmatrix} \mu_Y \\ \mu_Z \end{pmatrix} \quad \text{y} \quad \Sigma = \begin{pmatrix} \Sigma_{YY} & \Sigma_{YZ} \\ \Sigma_{ZY} & \Sigma_{ZZ} \end{pmatrix},$$

*donde  $\mu_Y$  y  $\Sigma_{YY}$  son el vector de medias y la matriz de covarianzas de  $Y$ , y  $\Sigma_{YZ}$  es la matriz de covarianzas de  $Y$  y  $Z$ . Supóngase que  $Z$  es el conjunto de nodos evidenciales. Entonces la distribución condicional de cualquier variable  $X_i \in Y$  dada  $Z$ , es normal, cuya media y varianza son cocientes de funciones polinomiales en las variables evidenciales y los correspondientes parámetros en  $\mu$  y  $\Sigma$ . Los polinomios son como mucho de grado uno en las variables condicionantes, en los parámetros de medias y varianzas, y son de grado dos en los parámetros de covarianzas. El polinomio del denominador es el mismo para todos los nodos.*



Universidad  
de Cantabria

## PROPAGACION SIMBOLICA EN REDES BAYESIANAS NORMALES Y MATHEMATICAS

```
(* Vector de medias y matriz de covarianzas *)
mean={m,0,0,1,0};
var={{a,1,1,2,1},{1,2,1,-1,1},{1,1,b,-1,c},
      {2,-1,-1,4,-2},{1,1,c,-2,6}};
(* Orden de conocimiento de la evidencia *)
evidencia={3,5}
(* Probabilidades Marginales *)
For[k=0,k<=Length[evidencia],k++,
  For[i=1,i<=Length[mean],i++,
    If[MemberQ[Take[evidencia,k],i],
      cmean=x[i];
      cvar=0,
      meany=mean[[i]];
      meanz=Tabla[{mean[[evidencia[[j]]]]},{j,1,k}];
      vary=var[[i,i]];
      If[k==0,
        cmean=Together[meany];
        cvar=Together[vary],
        varz=Tabla[Tabla[
          var[[evidencia[[t]],evidencia[[j]]]],
          {t,1,k}},{j,1,k}];
        covaryz=Tabla[{var[[evidencia[[t]]]],[i]},{t,1,k}];
        zaux=Tabla[{x[evidencia[[t]]]},{t,1,k}];
        aux=Inverse[varz];
        cmean=meany+Transpose[covaryz].aux.(zaux-menz);
        cvar=vary-Transpose[covaryz].aux.covaryz;]];
  Print["Nodos evidenciales ",k," Nodo ",i];
  Print["Media ",Together[cmean],"Var ",Together[cvar]];]]
```

Considérese el conjunto de variables

$$X = \{X_1, \dots, X_5\}$$

con vector de medias y matriz de covarianzas

$$\mu = \begin{pmatrix} m \\ 0 \\ 0 \\ 1 \\ 0 \end{pmatrix} \quad \text{y} \quad \Sigma = \begin{pmatrix} a & 1 & 1 & 2 & 1 \\ 1 & 2 & 1 & -1 & 1 \\ 1 & 1 & b & -1 & c \\ 2 & -1 & -1 & 4 & -2 \\ 1 & 1 & c & -2 & 6 \end{pmatrix}. \quad (7)$$

Nótese que la media de  $X_1$ , la varianza de  $X_1$  y  $X_3$ , y la covarianza de  $X_3$  y  $X_5$  están especificadas en forma simbólica.

Se desea conocer las probabilidades marginales iniciales de los nodos (no evidencia) y las probabilidades condicionales de los nodos dadas cada una de las evidencias  $\{X_3 = x_3\}$  y  $\{X_3 = x_3, X_5 = x_5\}$ . Las medias y varianzas condicionadas son expresiones racionales, es decir, cocientes de polinomios en los parámetros.



## EJEMPLO DE PROPAGACION SIMBOLICA

No Evidencia		
$X_i$	Media	Varianza
$X_1$	$m$	$a$
$X_2$	0	2
$X_3$	0	$b$
$X_4$	1	4
$X_5$	0	6
Evidencia $X_3 = x_3$		
$X_1$	$(bm + x_3)/b$	$(ab - 1)/b$
$X_2$	$(x_3)/b$	$(2b - 1)/b$
$X_3$	$x_3$	0
$X_4$	$(b - x_3)/b$	$(4b - 1)/b$
$X_5$	$(cx_3)/b$	$(6b - c^2)/b$
Evidencia $X_3 = x_3$ y $X_5 = x_5$		
$X_1$	$\frac{6bm - c^2m + (6 - c)x_3 + (b - c)x_5}{6b - c^2}$	$\frac{6ab + 2c - ac^2 - b - 6}{6b - c^2}$
$X_2$	$\frac{(6 - c)x_3 + (b - c)x_5}{6b - c^2}$	$\frac{11b + 2c - 2c^2 - 6}{6b - c^2}$
$X_3$	$x_3$	0
$X_4$	$\frac{6b - c^2 + (2c - 6)x_3 + (c - 2b)x_5}{6b - c^2}$	$\frac{20b + 4c - 4c^2 - 6}{6b - c^2}$
$X_5$	$x_5$	0