

3. Factorizacion de Cholesky

En estadística a menudo aparecen sistemas de ecuaciones $Ax=b$ donde la matriz A es definida positiva. Por ejemplo, el sistema de ecuaciones normales de un modelo de regresión lineal tiene la forma $X'Xb=y$. Aquí $A=X'X$ es definida positiva y simétrica. Se podría usar Eliminación Gaussiana para resolver el sistema de ecuaciones, pero no se explotaría la propiedad de definida positiva.

Si la matriz A es simétrica y definida positiva en lugar de factorizarse como LU , puede ser factorizada como $A=HH'$, donde H es una matriz triangular inferior, esta es llamada la Factorización Cholesky.

La existencia de la factorización Cholesky puede ser mostrada a través de la factorización LU . Es decir, $A=LU$. La matriz triangular superior U puede ser escrita como

$U=DU_1$ donde $D=diag(u_{11},u_{22},\dots,u_{nn})$ y U_1 es una matriz triangular superior con unos en su diagonal. Luego, $A=LDU_1$ y como $A=A'$ se tiene que $LDU_1=U_1'DL'$ de donde $D=(U_1')^{-1}LDU_1(L')^{-1}$

La matriz $(U_1')^{-1}L$ es una matriz triangular inferior unitaria y la matriz $U_1(L')^{-1}$ es una matriz triangular superior unitaria. Por lo tanto,

$$(U_1')^{-1}L=U_1(L')^{-1}=I$$

En consecuencia, $U_1=L'$ y A puede ser escrita como $A=LDL'$ donde L es una matriz triangular inferior unitaria. Cuando A es definida positiva los elementos de la diagonal de D son positivas y se puede escribir $D=D^{1/2}D^{1/2}$, donde $D^{1/2}=diag(\sqrt{u_{11}},\sqrt{u_{22}},\dots,\sqrt{u_{nn}})$ Así que.

$$A=LDL'=LD^{1/2}D^{1/2}L'=HH', \text{ con } H=LD^{1/2}.$$

Es decir,

$$\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} h_{11} & 0 & \dots & 0 \\ h_{21} & h_{22} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ h_{n1} & h_{n2} & \dots & h_{nn} \end{bmatrix} \begin{bmatrix} h_{11} & h_{21} & \dots & h_{n1} \\ 0 & h_{22} & \dots & h_{n2} \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & h_{nn} \end{bmatrix}$$

De donde

$$h_{11} = \sqrt{a_{11}} \qquad h_{i1} = \frac{a_{i1}}{h_{11}} \qquad i=1,2,\dots,n$$

$$\sum_{k=1}^i h_{ik}^2 = a_{ii}, \qquad a_{ij} = \sum_{k=1}^j h_{ik}h_{jk} \qquad j<i$$

3.1 Algoritmo para la Factorización Cholesky.

Dada una matriz simétrica y definida positiva A de orden n x n, el siguiente algoritmo calcula la matriz H de la factorización Cholesky. H es calculada fila por fila y es almacenada en la parte triangular inferior de A.

For k=1,2,...,n do

For i=1,2,...,k-1 do

$$a_{ki}=h_{ki}=\frac{1}{h_{ii}}\left(a_{ki}-\sum_{j=1}^{i-1}h_{ij}h_{kj}\right)$$

$$a_{kk}=h_{kk}=\sqrt{a_{kk}-\sum_{j=1}^{k-1}h_{kj}^2}$$

Nota: Cuando k=1 el loop interior no es calculado. Al ser A definida positiva se asegura que la cantidad dentro de la raíz cuadrada es siempre positiva.

Ejemplo 3. Obtener la factorización Cholesky de la matriz

$$A=\begin{bmatrix} 4 & 2 & 2 & 4 \\ 2 & 5 & 7 & 0 \\ 2 & 7 & 19 & 11 \\ 4 & 0 & 11 & 25 \end{bmatrix}$$

- A) Manualmente
- B) Usando la función **Chol** de R y MATLAB

Solución:

a) Cálculo de la primera fila de H (k=1)

$$h_{11}=\sqrt{4}=2$$

Cálculo de la Segunda fila de H (k=2)

$$h_{21}=\frac{a_{21}}{h_{11}}=\frac{2}{2}=1$$

$$h_{22}=\sqrt{a_{22}-h_{21}^2}=\sqrt{5-1^2}=2$$

Cálculo de la tercera fila de H (k=3)

$$h_{31} = \frac{a_{31}}{h_{11}} = \frac{2}{2} = 1$$

$$h_{32} = \frac{1}{h_{22}}(a_{32} - h_{21}h_{31}) = \frac{1}{2}(7 - 1) = 3$$

$$h_{33} = \sqrt{a_{33} - (h_{31}^2 + h_{32}^2)} = \sqrt{19 - 1^2 - 3^2} = 3$$

Cálculo de la cuarta fila de H (k=4)

$$h_{41} = \frac{a_{41}}{h_{11}} = \frac{4}{2} = 2$$

$$h_{42} = \frac{1}{h_{22}}(a_{42} - h_{21}h_{41}) = \frac{1}{2}(0 - 2) = -1$$

$$h_{43} = \frac{1}{h_{33}}(a_{43} - h_{31}h_{41} - h_{32}h_{42}) = \frac{1}{3}(11 - 1 \cdot 2 - 3 \cdot (-1)) = 4$$

$$h_{44} = \sqrt{a_{44} - (h_{41}^2 + h_{42}^2 + h_{43}^2)} = \sqrt{25 - 2^2 - (-1)^2 - 4^2} = 2$$

b) En R,

```
> A=cbind(c(4,2,2,4),c(2,5,7,0),c(2,7,19,11),c(4,0,11,25))
```

```
> A
```

```
  [,1] [,2] [,3] [,4]
[1,]  4  2  2  4
[2,]  2  5  7  0
[3,]  2  7 19 11
[4,]  4  0 11 25
```

```
> chol(A)
```

```
  [,1] [,2] [,3] [,4]
[1,]  2  1  1  2
[2,]  0  2  3 -1
[3,]  0  0  3  4
[4,]  0  0  0  2
```

```
> t(chol(A))%*%chol(A)
```

```
  [,1] [,2] [,3] [,4]
[1,]  4  2  2  4
[2,]  2  5  7  0
[3,]  2  7 19 11
[4,]  4  0 11 25
```

```
>
```

Usando MATLAB

» A

A =

4	2	2	4
2	5	7	0
2	7	19	11
4	0	11	25

» L=chol(A)

L =

2	1	1	2
0	2	3	-1
0	0	3	4
0	0	0	2

»

Notar que tanto R como MATLAB dan la matriz triangular superior.

3.2 Solución del sistema de ecuaciones $Ax=b$ usando la factorización Cholesky

El sistema de ecuaciones $Ax=b$ se transforma en $HH'x=b$. Luego, se resuelve el sistema triangular inferior $Hy=b$ y después el sistema triangular superior $H'x=y$.

Ejemplo 4 : Resolver el sistema $Ax=b$, donde A está dado en el ejemplo 3 y el vector de términos independientes b es $(-1 \ 1 \ 5/2 \ 1/4)'$.

Solución: Resolviendo el sistema triangular inferior $Hy=b$, para y con

$$H = \begin{pmatrix} 2 & 0 & 0 & 0 \\ 1 & 2 & 0 & 0 \\ 1 & 3 & 3 & 0 \\ 2 & -1 & 4 & 2 \end{pmatrix}$$

se obtiene $y_1 = -1/2$, $y_2 = 1/2(1+1/2) = 3/4$, $y_3 = 1/3(5/2 - 9/4 + 1/2) = 1/4$, y $y_4 = 1/2(1/4 - 1 + 3/4 + 1) = 1/2$. Resolviendo el sistema $H'x = y$ para x , con

$$H' = \begin{pmatrix} 2 & 1 & 1 & 2 \\ 0 & 2 & 3 & -1 \\ 0 & 0 & 3 & 4 \\ 0 & 0 & 0 & 2 \end{pmatrix}$$

se obtiene, $x_4 = 1/4$, $x_3 = 1/3(1/4 - 1) = -1/4$, $x_2 = 1/2(3/4 + 1/4 + 3/4) = 7/8$ y, $x_1 = 1/2(-1/2 - 1/2 + 1/4 - 7/8) = -13/16$.

3.3 Aplicación a Regresión (Cuadrados Mínimos)

Dado el conjunto de datos (\mathbf{x}_i, y_i) ($i=1, \dots, n$) donde \mathbf{x}_i es un vector de dimension p de mediciones que se han hecho en la i -ésima observación y y_i es la respuesta que se ha observado, x es llamado el **vector de variables predictoras** y y es la **variable de respuesta**. Por ejemplo, se ha observado que una casa que cuesta 250,000 tiene 600 metros cuadrados de area construida, 6 habitaciones y 25 años de antigüedad. Es decir, se tiene el dato $((600, 6, 25), 250,000)$ Supongamos que tenemos como 150 de estos datos. El objetivo en regresión lineal es construir un modelo (lineal) que describa el comportamiento de la variable de respuesta según el comportamiento de las variables predictoras. En nuestro caso sería algo como:

$$\text{Precio} = b_0 + b_1 * \text{area} + b_2 * \text{habitaciones} + b_3 * \text{antigüedad} + \text{error aleatorio}$$

Los coeficientes b_0 , b_1 , b_2 y b_3 deben ser estimados usando los datos tomados, y el proceso es conocido como **ajustar un modelo de regresión lineal multiple**.

El modelo aplicado a todas las observaciones puede ser escrito matricialmente como

$$Y = XB + e,$$

donde Y es el vector de variable de respuesta,

X es una matriz $n \times p+1$, considerando que hemos incluido el intercepto, es decir cada fila de X es de la forma $(1, \mathbf{x}_i)$,

B es un vector de dimension $p+1$ de parámetros a ser estimados,

e es un vector de errores aleatorios.

La idea (K. Gauss, 1828) para estimar B es minimizar la suma de cuadrados de los errores $Q(B) = \|e\|^2 = e'e = (Y - XB)'(Y - XB)$ con respecto a B .

Derivando con respecto a B e igualando a cero se obtiene el sistema de ecuaciones lineales

$$X'XB=X'Y$$

éste es llamado las **ecuaciones normales del modelo**.

$X'X$ es claramente simétrica. Por otro lado, si X es de rango completo, en nuestro caso $\text{rango}(X)=p+1$, entonces $w \neq 0$ implica que $Xw \neq 0$. En consecuencia, $w'X'Xw = \|Xw\|^2 > 0$ para todo $w \neq 0$, así que $X'X$ también es definida positiva y la Factorización Cholesky puede ser aplicada. Hay que notar que si X no es de rango completo entonces la propiedad de definida positiva no se cumple.

La existencia y unicidad de la solución \hat{B} de las ecuaciones normales está condicionada a que X sea de rango completo. La forma explícita de la solución es

$$\hat{B} = (X'X)^{-1} X'Y$$

Otras cantidades de interés son:

El vector de valores ajustados o predichos:

$$\hat{Y} = X\hat{B} = X(X'X)^{-1} X'Y$$

El vector de residuales:

$$\hat{e} = Y - \hat{Y}$$

La suma de cuadrados del error o residual

$$SSE = e'e = (Y - X\hat{B})'(Y - X\hat{B}) = Y'[I - X(X'X)^{-1}X']Y$$

La matriz de Covarianza del vector de parametros estimados \hat{B}

$$(X'X)^{-1}\sigma^2$$

donde σ^2 es la varianza poblacional de las y_i (o equivalente de los errores e_i). Esta varianza es estimada por $MSE = \frac{SSE}{n-p-1}$ donde p es el número de variables predictoras.

A $(X'X)^{-1}$ también le dicen la matriz no escalada de covarianza.

Algoritmo para regresión usando Factorización Cholesky

El siguiente algoritmo resuelve las ecuaciones normales del modelo de regresión y calcula ciertas cantidades importantes

- a) Calcular $w=X'Y$
- b) Calcular la factorizacion Cholesky HH' de $X'X$.

- c) Resolver el sistema triangular $H\hat{z}=w$ para \hat{z}
- d) Resolver el sistema triangular $H'\hat{B}=z$ para \hat{B}
- e) Calcular la suma de cuadrados residual por $SSE=Y'Y-z'z$
- f) Calcular el vector de predicciones $\hat{Y}=X\hat{B}$
- g) Invertir H
- h) Calcular la matriz de covarianza no escalada, usando $(X'X)^{-1}=H^{-1}H^{-1}$

Ejemplo 5. Ajustar un modelo de regresión lineal múltiple para el siguiente conjunto de datos

Y	x1	x2	x3
12	4	5	6
23	8	9	12
41	12	3	23
89	11	17	21
18	8	19	39
39	19	21	45
56	9	22	42
9	13	9	18

Usando R y MATLAB.

Solución:

En R,

Haremos uso de las funciones forwardsolve y backsolve

```
> eje1=read.table("c://computacional//ejechol.txt",header=T)
> eje1
  Y x1 x2 x3
1 12  4  5  6
2 23  8  9 12
3 41 12  3 23
4 89 11 17 21
5 18  8 19 39
6 39 19 21 45
7 56  9 22 42
8  9 13  9 18
> X=cbind(rep(1,8),eje1[,2:4])
> X
  rep(1, 8) x1 x2 x3
1      1  4  5  6
2      1  8  9 12
3      1 12  3 23
4      1 11 17 21
5      1  8 19 39
6      1 19 21 45
```

```

7      1 9 22 42
8      1 13 9 18
> dim(X)
[1] 8 4
> X=as.matrix(X)
> colnames(X)=NULL
> X
  [,1] [,2] [,3] [,4]
1  1   4   5   6
2  1   8   9  12
3  1  12   3  23
4  1  11  17  21
5  1   8  19  39
6  1  19  21  45
7  1   9  22  42
8  1  13   9  18
> y=eje1[,1]
> y
[1] 12 23 41 89 18 39 56 9
> w=t(X)%*%y
> H=chol(t(X)%*%X)
> H
  [,1] [,2] [,3] [,4]
[1,] 2.828427 29.69848 37.123106 72.83200
[2,] 0.000000 11.74734  6.682364 20.68553
[3,] 0.000000  0.00000 18.660681 26.47394
[4,] 0.000000  0.00000  0.000000 18.72803
> z=forwardsolve(t(H),w)
> z
  [,1]
[1,] 101.46982
[2,] 16.64207
[3,] 26.73625
[4,] -16.62288
> b=backsolve(H,z)
> #calculo del vector de coeficientes de regresion
> b
  [,1]
[1,] 8.1911264
[2,] 1.4482906
[3,] 2.6919893
[4,] -0.8875937
> #calculo de la suma de cuadrados del error
> sse=t(y)%*%y-t(z)%*%z
> sse
  [,1]

```



```

[1,] 3772.769
> #calculo del vector de predicciones
> yhat=X%*%b
> yhat
  [1]
1 22.11867
2 33.35423
3 13.23193
4 51.24667
5 36.30909
6 52.29871
7 43.17057
8 35.27012
> #calculo de la matriz de covarianza no escalonada
> cov=t(solve(H))%*%solve(H)
> cov
  [1] [2] [3] [4]
[1,] 0.12500000 -0.3160129 -0.13550820 0.05448148
[2,] -0.31601286 0.8061594 0.33998376 -0.14207039
[3,] -0.13550820 0.3399838 0.15070076 -0.06156841
[4,] 0.05448148 -0.1420704 -0.06156841 0.03492952

>#Verificacion de resultados
>#Haciendo la regresion lineal multiple
>l1=lm(Y~.,data=eje1)
> attributes(l1)
$names
 [1] "coefficients" "residuals" "effects" "rank"
 [5] "fitted.values" "assign" "qr" "df.residual"
 [9] "xlevels" "call" "terms" "model"

$class
[1] "lm"

> # Mostrando el vector de coeficientes de regresion
> l1$coef
(Intercept) x1 x2 x3
 8.1911264 1.4482906 2.6919893 -0.8875937
> #Mostrando los valores estimados(predichos) de la variable de respuesta
> l1$fitted.values
 1 2 3 4 5 6 7 8
22.11867 33.35423 13.23193 51.24667 36.30909 52.29871 43.17057 35.27012
>

```

En Matlab

Haremos uso de las funciones `forelem` y `backsub` que están disponibles en el folder `c:\matlab\acuna`

```
» X=[1 4 5 6; 1 8 9 12; 1 12 3 23; 1 11 17 21; 1 8 19 39; 1 19 21 45; 1 9 22 42; 1 13 9 18]
```

```
» X  
X =
```

```
1  4  5  6  
1  8  9 12  
1 12  3 23  
1 11 17 21  
1  8 19 39  
1 19 21 45  
1  9 22 42  
1 13  9 18
```

```
» y=[12;23;41;89;18;39;56;9]  
» y
```

```
y =
```

```
12  
23  
41  
89  
18  
39  
56  
9
```

```
» w=X'*y
```

```
w =
```

```
287  
3209  
4377  
8131
```

```
» H=chol(X'*X)
```

```
H =
```

```
2.8284 29.6985 37.1231 72.8320
  0    11.7473  6.6824 20.6855
  0     0      18.6607 26.4739
  0     0       0      18.7280
```

```
» addpath c:\matlab\acuna
» z=forelm(H',w)
```

```
z =
```

```
101.4698
 16.6421
 26.7363
-16.6229
```

```
» b=backsub(H,z)
```

```
b =
```

```
8.1911
 1.4483
 2.6920
-0.8876
```

```
» load y
» y
```

```
y =
```

```
12
23
41
89
18
39
56
9
```

```
» load z
» z
```

```
z =
```

```
101.4698
 16.6421
```

26.7363
-16.6229

» %calculo de la suma de cuadrados del error
» $sse=y'y-z'z$

sse =

3.7728e+003

» %Calculo del vector de predicciones

» $\hat{y}=X*b$

yhat =

22.1187
33.3542
13.2319
51.2467
36.3091
52.2987
43.1706
35.2701

» %Calculo de la matriz de covarianza no escalada

» $cov=(inv(H))'*inv(H)$

cov =

0.1250	-0.3160	-0.1355	0.0545
-0.3160	0.8062	0.3400	-0.1421
-0.1355	0.3400	0.1507	-0.0616
0.0545	-0.1421	-0.0616	0.0349

»

Ahora, solamente para comparar resultados usaremos la función **regress** del toolbox **stats** de MATLAB. Esta función no usa la factorización Cholesky, si no la factorización QR que sera vista mas adelante.

» load X

» load y

» addpath c:\matlab\toolbox\stats

» help regress

REGRESS Multiple linear regression using least squares.

$b = \text{REGRESS}(y,X)$ returns the vector of regression coefficients, B.

Given the linear model: $y = Xb$,

(X is an $n \times p$ matrix, y is the $n \times 1$ vector of observations.)

$[B,BINT,R,RINT,STATS] = \text{REGRESS}(y,X,\alpha)$ uses the input, ALPHA to calculate $100(1 - \text{ALPHA})$ confidence intervals for B and the residual vector, R, in BINT and RINT respectively.

The vector STATS contains the R-square statistic along with the F and p values for the regression.

» $b = \text{REGRESS}(y,X)$

b =

8.1911
1.4483
2.6920
-0.8876

» $[b,bint,r,rint,stats] = \text{REGRESS}(y,X,.05)$

b =

8.1911
1.4483
2.6920
-0.8876

bint =

-81.0179 97.4001
-7.4006 10.2972
-5.2202 10.6042
-5.4406 3.6654

r =

-10.1187
-10.3542
27.7681

37.7533
-18.3091
-13.2987
12.8294
-26.2701

rint =

-77.8872 57.6499
-92.3572 71.6487
16.7447 38.7915
2.1904 73.3163
-83.3236 46.7054
-65.2154 38.6179
-54.6301 80.2890
-96.3175 43.7773

stats =

0.2516 0.4482 0.7322