

scriptregresion.R

maru

Thu Nov 16 09:20:50 2017

```
setwd("~/Dropbox/Estadistica(Q)verano2017/clasespracticaverano2017")
toluca<-read.table("toluca.txt",header=T) #header=T lee los nombres de las columnas desde el archivo

attach(toluca) #para poder trabajar con las variables de toluca directamente
View(toluca)
#####
# a) grafico de dispersion
#####

plot(tamano,horas,main="diagrama de dispersion
de horas vs. tamano")
# ponemos el tamano como variable independiente, las horas como variable dependiente

#####
#b) El modelo
#####
# Responder con papel y lapiz. Definir variables y parametros. Cuantos parametros
# tiene este modelo?

#####
#c) Ajuste del modelo
#####
#la instruccion lm (linear model) ajusta la recta de minimos cuadrados a los datos

salida<-lm(horas~tamano)
#como el aov, el lm produce un objeto (una lista) que contiene muchas cosas
names(salida)

## [1] "coefficients" "residuals" "effects" "rank"
## [5] "fitted.values" "assign" "qr" "df.residual"
## [9] "xlevels" "call" "terms" "model"

# para obtener los coeficientes, hay dos formas
salida$coefficients

## (Intercept) tamano
## 62.365859 3.570202


coefficients(salida)

## (Intercept) tamano
## 62.365859 3.570202
```

```
# (Intercept)      tamaño
# 62.365859      3.570202


#superponemos la recta de minimos cuadrados al grafico
plot(tamaño,horas,main="diagrama de dispersion
      de horas vs. tamaño")
abline(salida,col="red")
```

diagrama de dispersion de horas vs. tamaño



```
# la instruccion abline agrega una o mas lineas rectas al grafico
# se le pueden dar la ordenada al origen y la pendiente, alternativamente
plot(tamaño,horas,main="diagrama de dispersion
      de horas vs. tamaño")
abline(62.3659,3.5702,col="green")
```

diagrama de dispersion de horas vs. tamaño



```
?abline
```

```
summary(salida)
```

```
##
## Call:
## lm(formula = horas ~ tamaño)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -83.876 -34.088  -5.982  38.826 103.528
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept)   62.366     26.177   2.382  0.0259 *
## tamaño         3.570       0.347  10.290 4.45e-10 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 48.82 on 23 degrees of freedom
## Multiple R-squared:  0.8215, Adjusted R-squared:  0.8138
## F-statistic: 105.9 on 1 and 23 DF,  p-value: 4.449e-10
```

```
names(summary(salida))
```

```
## [1] "call"          "terms"         "residuals"    "coefficients"
## [5] "aliased"       "sigma"         "df"           "r.squared"
## [9] "adj.r.squared" "fstatistic"    "cov.unscaled"
```

```
names(salida)
```

```
## [1] "coefficients" "residuals" "effects" "rank"  
## [5] "fitted.values" "assign" "qr" "df.residual"  
## [9] "xlevels" "call" "terms" "model"
```

```
#####  
#d) estimamos el valor esperado de las horas cuando tamaño = 90 y 120  
#####
```

```
coefficients(salida)[1]+coefficients(salida)[2]*90
```

```
## (Intercept)  
## 383.684
```

```
coefficients(salida)[1]+coefficients(salida)[2]*120
```

```
## (Intercept)  
## 490.7901
```

```
# comparar con los fitted.values que calcula directamente el R.  
# que observacion corresponde a tamaño=90?
```

```
fitted.values(salida)
```

```
##      1      2      3      4      5      6      7      8  
## 133.7699 169.4719 169.4719 169.4719 205.1739 205.1739 240.8760 240.8760  
##      9     10     11     12     13     14     15     16  
## 240.8760 276.5780 312.2800 312.2800 312.2800 347.9820 347.9820 347.9820  
##     17     18     19     20     21     22     23     24  
## 383.6840 383.6840 383.6840 383.6840 419.3861 419.3861 455.0881 455.0881  
##      25  
## 490.7901
```

```
cbind(tamaño,horas,fitted.values(salida),residuals(salida))
```

```
## tamaño horas  
## 1 20 113 133.7699 -20.7698990  
## 2 30 121 169.4719 -48.4719192  
## 3 30 212 169.4719 42.5280808  
## 4 30 273 169.4719 103.5280808  
## 5 40 160 205.1739 -45.1739394  
## 6 40 244 205.1739 38.8260606  
## 7 50 221 240.8760 -19.8759596  
## 8 50 157 240.8760 -83.8759596  
## 9 50 268 240.8760 27.1240404  
## 10 60 224 276.5780 -52.5779798  
## 11 70 252 312.2800 -60.2800000  
## 12 70 361 312.2800 48.7200000  
## 13 70 323 312.2800 10.7200000  
## 14 80 399 347.9820 51.0179798
```

```
## 15      80    342 347.9820 -5.9820202
## 16      80    352 347.9820  4.0179798
## 17      90    389 383.6840  5.3159596
## 18      90    468 383.6840 84.3159596
## 19      90    377 383.6840 -6.6840404
## 20      90    376 383.6840 -7.6840404
## 21     100    353 419.3861 -66.3860606
## 22     100    420 419.3861  0.6139394
## 23     110    435 455.0881 -20.0880808
## 24     110    421 455.0881 -34.0880808
## 25     120    546 490.7901 55.2098990
```

```
# cual es el valor ajustado para la vigesima observacion (la numero 20)?
# compararla con los valores ajustados para las observaciones 17 a 19.
# cual es el residuo de la vigesima observacion (la numero 20)?
# compararla con los residuos de las observaciones 17 a 19.
```

```
#####
#e) intervalos de confianza para coeficientes
#####
```

```
qt(0.975,df=23) #2.068658
```

```
## [1] 2.068658
```

```
#los coeficientes estimados
summary(salida)$coef[,1]
```

```
## (Intercept)      tamaño
##  62.365859      3.570202
```

```
# (Intercept)      tamaño
# 62.365859      3.570202
```

```
#el desvio estandar de los coeficientes estimados
summary(salida)$coef[,2]
```

```
## (Intercept)      tamaño
##  26.1774339      0.3469722
```

```
#(Intercept)      tamaño
#26.1774339      0.3469722
# donde se ven en el objeto "salida"?
```

```
# que parametro estima la siguiente instruccion?
summary(salida)$sigma
```

```
## [1] 48.82331
```

```

# 48.82331
# donde figura esta informacion en la tabla que da summary(salida)?
# la podemos calcular a mano

n<-length(horas)
sqrt(sum(salida$res^2)/(n-2))

## [1] 48.82331

#como se calculan los desvios estandares de los coeficientes a partir de el?

#los extremos superiores de los ic
summary(salida)$coef[,1]+ summary(salida)$coef[,2]*qt(0.975,df=23)

## (Intercept)      tamaño
## 116.518006      4.287969

#los extremos inferiores de los ic
summary(salida)$coef[,1]- summary(salida)$coef[,2]*qt(0.975,df=23)

## (Intercept)      tamaño
## 8.213711         2.852435

# el R calcula todo automaticamente
confint(salida)

##              2.5 %      97.5 %
## (Intercept) 8.213711 116.518006
## tamaño      2.852435  4.287969

#####
#f) Rcuadrado
#####
# en "salida" puede verse. Donde? Que significa? Sino,
names(summary(salida))

## [1] "call"          "terms"           "residuals"      "coefficients"
## [5] "aliases"         "sigma"           "df"              "r.squared"
## [9] "adj.r.squared"  "fstatistic"     "cov.unscaled"

summary(salida)$r.squared

## [1] 0.8215335

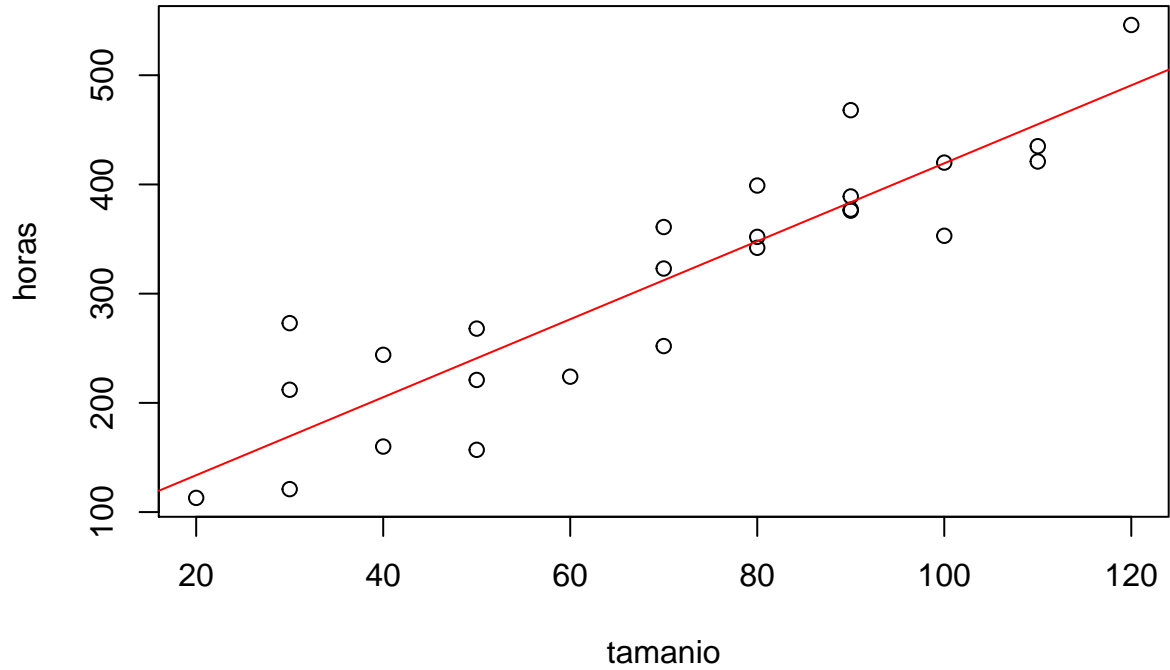
#0.8215335

#####
#g) validacion de supuestos

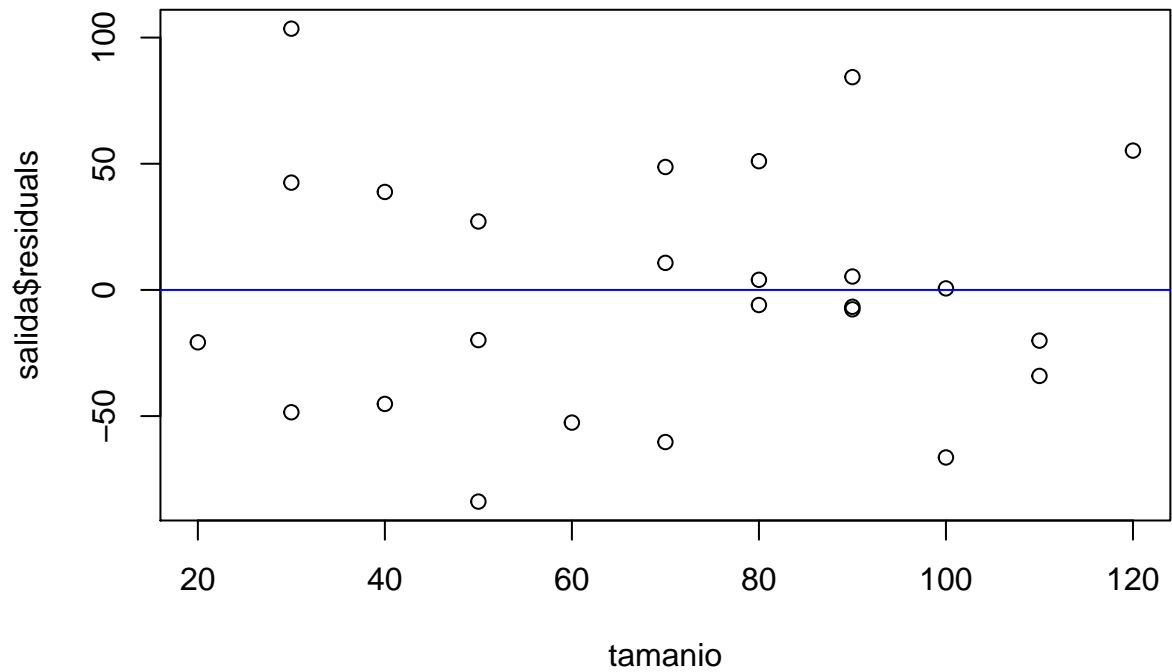
```

```
#####  
# en funcion de los siguientes graficos, decida si se satisfacen los supuestos de linealidad  
#y homoscedasticidad
```


```
#1)  
plot(tamano,horas)  
abline(salida,col=2)
```



```
#2)  
plot(tamano,salida$residuals)  
abline(a=0,b=0,col=4)
```



```
#3)
plot(salida$fitted.values,salida$residuals)
abline(a=0,b=0,col=4)
```



```
# que se grafica en cada uno de los graficos anteriores?

#compare graficos 1 y 2 mediante las siguientes instrucciones



par(mfrow=c(1,2))
plot(tamaño,horas)
```



```
abline(salida,col=2)
```

```
plot(tamano,salida$residuals)
```

```
abline(a=0,b=0,col=4)
```



#compare graficos 2 y 3 mediante las siguientes instrucciones



```
par(mfrow=c(1,2))
```

```
plot(tamano,salida$residuals)
```

```
abline(a=0,b=0,col=4)
```

```
plot(salida$fitted.values,salida$residuals)
```

```
abline(a=0,b=0,col=4)
```



```
#Rptas.:
#vemos que se satisfacen los supuestos de linealidad y homoscedasticidad ya que en el grafico
#de dispersion vemos que los puntos estan cerca de una recta y la variabilidad de las Y's es
#parecida para los distintos valores de x.
#En los 2 graficos restantes vemos una nube de puntos sin estructura alrededor de la recta y=0

#que hay en cada una de las columnas de la siguiente matriz? relacione sus valores

cbind(horas,salida$fitted.values,salida$residuals,rstandard(salida))
```

```
##      horas
## 1    113 133.7699 -20.7698990 -0.46589980
## 2    121 169.4719 -48.4719192 -1.05881760
## 3    212 169.4719  42.5280808  0.92898076
## 4    273 169.4719 103.5280808  2.26146098
## 5    160 205.1739 -45.1739394 -0.96751587
## 6    244 205.1739  38.8260606  0.83155975
## 7    221 240.8760 -19.8759596 -0.41993651
## 8    157 240.8760 -83.8759596 -1.77211959
## 9    268 240.8760  27.1240404  0.57307295
## 10   224 276.5780 -52.5779798 -1.10201238
## 11   252 312.2800 -60.2800000 -1.26011565
## 12   361 312.2800  48.7200000  1.01846109
## 13   323 312.2800  10.7200000  0.22409489
## 14   399 347.9820  51.0179798  1.06931543
## 15   342 347.9820  -5.9820202 -0.12538063
## 16   352 347.9820   4.0179798  0.08421517
## 17   389 383.6840   5.3159596  0.11231485
## 18   468 383.6840  84.3159596  1.78141585
## 19   377 383.6840  -6.6840404 -0.14121947
## 20   376 383.6840  -7.6840404 -0.16234734
```


```
## 21 353 419.3861 -66.3860606 -1.42182789
## 22 420 419.3861 0.6139394 0.01314909
## 23 435 455.0881 -20.0880808 -0.43880279
## 24 421 455.0881 -34.0880808 -0.74461792
## 25 546 490.7901 55.2098990 1.23844036
```

#en funcion de los siguientes graficos y salidas, decida si se satisface el supuesto de normalidad

```
par(mfrow=c(1,1))
```


```
qqnorm(rstandard(salida),main="qqplot de residuos estandarizados")
```

qqplot de residuos estandarizados



```
boxplot(rstandard(salida),main="boxplot de residuos estandarizados")
```

boxplot de residuos estandarizados



```
shapiro.test(rstandard(salida))
```

```
##  
## Shapiro-Wilk normality test  
##  
## data:  rstandard(salida)  
## W = 0.97861, p-value = 0.8563
```

```
#Rptas.:  
# Shapiro-Wilk normality test  
#  
# data:  rstandard(salida)  
# W = 0.9786, p-value = 0.8563
```

```
#segun el qqplot y boxplot, los residuos estandarizados son aproximadamente normales y segun  
#el test shapiro no rechazamos el supuesto de normalidad a nivel 0.2.  
#con lo cual podemos asumir valido el supuesto de normalidad de los errores.
```

```
#####  
#h) estimador e IC para E(Y) cuando X=90 y X=120  
#####
```

```
#para hallar el estimador de E(Y) cuando X=90 tenemos 2 posibilidades  
#a mano  
salida$coef
```

```
## (Intercept)      tamaño  
## 62.365859      3.570202
```

```
62.365859+3.570202*90
```

```
## [1] 383.684
```

```
#383.684  
coefficients(salida)[1]+coefficients(salida)[2]*90
```

```
## (Intercept)  
##      383.684
```

```
#con los valores ajustados de la salida  
cbind(tamano,salida$fitted.values)
```

```
##      tamano  
## 1      20 133.7699  
## 2      30 169.4719  
## 3      30 169.4719  
## 4      30 169.4719  
## 5      40 205.1739  
## 6      40 205.1739  
## 7      50 240.8760  
## 8      50 240.8760  
## 9      50 240.8760  
## 10     60 276.5780  
## 11     70 312.2800  
## 12     70 312.2800  
## 13     70 312.2800  
## 14     80 347.9820  
## 15     80 347.9820  
## 16     80 347.9820  
## 17     90 383.6840  
## 18     90 383.6840  
## 19     90 383.6840  
## 20     90 383.6840  
## 21    100 419.3861  
## 22    100 419.3861  
## 23    110 455.0881  
## 24    110 455.0881  
## 25    120 490.7901
```

```
#que componente/s tengo que mirar? corroborar que es igual al calculo hecho a mano
```

```
#17 a 20
```

```
#383.6840
```

```
#para calcular un Ic para E(Y) cuando X=90 tambien tenemos dos posibilidades
```

```
#1) con el siguiente comando, que calcula los estimadores e IC 95% correspondientes a todas  
# las observaciones
```

```
predict(salida, interval="confidence")
```

```
##      fit      lwr      upr  
## 1 133.7699  92.58736 174.9524
```

```
## 2 169.4719 134.36734 204.5765
## 3 169.4719 134.36734 204.5765
## 4 169.4719 134.36734 204.5765
## 5 205.1739 175.64938 234.6985
## 6 205.1739 175.64938 234.6985
## 7 240.8760 216.09481 265.6571
## 8 240.8760 216.09481 265.6571
## 9 240.8760 216.09481 265.6571
## 10 276.5780 255.14090 298.0151
## 11 312.2800 292.08026 332.4797
## 12 312.2800 292.08026 332.4797
## 13 312.2800 292.08026 332.4797
## 14 347.9820 326.54494 369.4191
## 15 347.9820 326.54494 369.4191
## 16 347.9820 326.54494 369.4191
## 17 383.6840 358.90290 408.4652
## 18 383.6840 358.90290 408.4652
## 19 383.6840 358.90290 408.4652
## 20 383.6840 358.90290 408.4652
## 21 419.3861 389.86150 448.9106
## 22 419.3861 389.86150 448.9106
## 23 455.0881 419.98350 490.1927
## 24 455.0881 419.98350 490.1927
## 25 490.7901 449.60756 531.9726
```

```
#o tambien...
```

```
predict(salida,interval="confidence",level=0.95)
```

```
##      fit      lwr      upr
## 1 133.7699  92.58736 174.9524
## 2 169.4719 134.36734 204.5765
## 3 169.4719 134.36734 204.5765
## 4 169.4719 134.36734 204.5765
## 5 205.1739 175.64938 234.6985
## 6 205.1739 175.64938 234.6985
## 7 240.8760 216.09481 265.6571
## 8 240.8760 216.09481 265.6571
## 9 240.8760 216.09481 265.6571
## 10 276.5780 255.14090 298.0151
## 11 312.2800 292.08026 332.4797
## 12 312.2800 292.08026 332.4797
## 13 312.2800 292.08026 332.4797
## 14 347.9820 326.54494 369.4191
## 15 347.9820 326.54494 369.4191
## 16 347.9820 326.54494 369.4191
## 17 383.6840 358.90290 408.4652
## 18 383.6840 358.90290 408.4652
## 19 383.6840 358.90290 408.4652
## 20 383.6840 358.90290 408.4652
## 21 419.3861 389.86150 448.9106
## 22 419.3861 389.86150 448.9106
## 23 455.0881 419.98350 490.1927
## 24 455.0881 419.98350 490.1927
```

```
## 25 490.7901 449.60756 531.9726
```

```
cbind(tamano,predict(salida,interval="confidence",level=0.95))
```

```
##      tamano      fit      lwr      upr
## 1         20 133.7699  92.58736 174.9524
## 2         30 169.4719 134.36734 204.5765
## 3         30 169.4719 134.36734 204.5765
## 4         30 169.4719 134.36734 204.5765
## 5         40 205.1739 175.64938 234.6985
## 6         40 205.1739 175.64938 234.6985
## 7         50 240.8760 216.09481 265.6571
## 8         50 240.8760 216.09481 265.6571
## 9         50 240.8760 216.09481 265.6571
## 10        60 276.5780 255.14090 298.0151
## 11        70 312.2800 292.08026 332.4797
## 12        70 312.2800 292.08026 332.4797
## 13        70 312.2800 292.08026 332.4797
## 14        80 347.9820 326.54494 369.4191
## 15        80 347.9820 326.54494 369.4191
## 16        80 347.9820 326.54494 369.4191
## 17        90 383.6840 358.90290 408.4652
## 18        90 383.6840 358.90290 408.4652
## 19        90 383.6840 358.90290 408.4652
## 20        90 383.6840 358.90290 408.4652
## 21       100 419.3861 389.86150 448.9106
## 22       100 419.3861 389.86150 448.9106
## 23       110 455.0881 419.98350 490.1927
## 24       110 455.0881 419.98350 490.1927
## 25       120 490.7901 449.60756 531.9726
```

```
#que fila/s tengo que mirar? ?cual es el IC?
```

```
#17 a 20
```

```
#[358.90290,408.4652]
```

```
#2) con el siguiente comando, que calcula el estimador e IC correspondiente a X=90 unicamente  
predict(salida,newdata=data.frame(tamano=90),interval="confidence")
```

```
##      fit      lwr      upr
## 1 383.684 358.9029 408.4652
```

```
#      fit      lwr      upr  
# 1 383.684 358.9029 408.4652
```

```
#####  
#estimador e IC para E(Y) cuando X=120  
#####
```

```
#resolver utilizando los comandos anteriores que considere adecuados, adaptandolos  
#para el caso X=120
```

```
#estimador de E(Y) cuando X=120
```

```
salida$coef
```

```
## (Intercept)    tamaño  
## 62.365859     3.570202
```

```
62.365859+3.570202*120
```

```
## [1] 490.7901
```

```
#490.7901
```

```
#Ic para E(Y) cuando X=120
```

```
predict(salida,newdata=data.frame(tamaño=120),interval="confidence")
```

```
##      fit      lwr      upr  
## 1 490.7901 449.6076 531.9726
```

```
#      fit      lwr      upr  
# 1 490.7901 449.6076 531.9726
```

```
#el IC es [449.6076, 531.9726]
```

```
#####  
#comparacion entre las longitudes de los IC's  
#####
```

```
#que intervalo tiene menor longitud? A que se debe?
```

```
IC.90<-predict(salida,newdata=data.frame(tamaño=90),interval="confidence")  
IC.120<-predict(salida,newdata=data.frame(tamaño=120),interval="confidence")
```

```
long.IC.90<-IC.90[3]-IC.90[2]  
long.IC.120<-IC.120[3]-IC.120[2]
```

```
long.IC.90 # 49.56229
```

```
## [1] 49.56229
```

```
long.IC.120 # 82.36508
```

```
## [1] 82.36508
```

```
#graficamente
```

```
plot(tamaño,horas,main="diagrama de dispersion  
de horas vs. tamaño")  
abline(salida,col="red",lwd=2)
```



```


equis<-seq(from=20,to=120,by=5)

IC<-predict(salida,newdata=data.frame(tamano=equis),interval="confidence")

points(equis,IC[,3],type="l",col="coral",lty=2,lwd=2)
points(equis,IC[,2],type="l",col="coral",lty=2,lwd=2)

```

diagrama de dispersion de horas vs. tamaño



#lty es una instruccion para que haga la linea punteada, lwd setea el grosor de la linea que dibuja

```
#####
```

#i) Intervalos de prediccion

```
#####
```

*#para resolver este item se pueden utilizar los mismos comandos que en el item anterior pero
#en la funcion "predict" hay que cambiar el argumento "interval", poniendo "prediction" en lugar
#de #confidence"*

#predictor de Y cuando X=90 (idem estimador de E(Y): 383.6840)

#IP para Y cuando X=90, tambien tenemos dos posibilidades

```
#####
```

*#1)el siguiente comando que calcula los predictores e IP correspondientes a todas
#las observaciones*

```
predict(salida,interval="prediction")
```

```
## Warning in predict.lm(salida, interval = "prediction"): predictions on current data refer to _future_
```

```
##          fit          lwr          upr
## 1  133.7699  24.69771 242.8421
## 2  169.4719  62.54638 276.3975
## 3  169.4719  62.54638 276.3975
## 4  169.4719  62.54638 276.3975
## 5  205.1739  99.94828 310.3996
## 6  205.1739  99.94828 310.3996
## 7  240.8760 136.88151 344.8704
## 8  240.8760 136.88151 344.8704
## 9  240.8760 136.88151 344.8704
## 10 276.5780 173.32931 379.8267
## 11 312.2800 209.28112 415.2789
## 12 312.2800 209.28112 415.2789
## 13 312.2800 209.28112 415.2789
## 14 347.9820 244.73335 451.2307
## 15 347.9820 244.73335 451.2307
## 16 347.9820 244.73335 451.2307
## 17 383.6840 279.68959 487.6785
## 18 383.6840 279.68959 487.6785
## 19 383.6840 279.68959 487.6785
## 20 383.6840 279.68959 487.6785
## 21 419.3861 314.16040 524.6117
## 22 419.3861 314.16040 524.6117
## 23 455.0881 348.16254 562.0136
## 24 455.0881 348.16254 562.0136
## 25 490.7901 381.71792 599.8623
```

#que fila/s tengo que mirar? ?cual es el IP?

#filas 17 a 20, IP=[279.68959,487.6785]

#2) el siguiente comando calcula el predictor e IP correspondiente a X=90 unicamente
`predict(salida,newdata=data.frame(tamano=90),interval="prediction")`

```
##          fit          lwr          upr
## 1  383.684 279.6896 487.6785
```

```
#####
#predictor e IP para Y cuando X=120
#####
```

#predictor de Y cuando X=120 (idem estimador de E(Y): 490.7901)
#IP para Y cuando X=120, tambien tenemos dos posibilidades

```
predict(salida,newdata=data.frame(tamano=120),interval="prediction")
```

```
##          fit          lwr          upr
## 1  490.7901 381.7179 599.8623
```

```
# fit          lwr          upr
# 1 490.7901 381.7179 599.8623
```

```
#####
#comparacion de las longitudes de los IP's entre s?
#####

#que intervalo tiene menor longitud? a que se debe?

IP.90<-predict(salida,newdata=data.frame(tamano=90),interval="prediction")
IP.120<-predict(salida,newdata=data.frame(tamano=120),interval="prediction")

long.IP.90<-IP.90[3]-IP.90[2]
long.IP.120<-IP.120[3]-IP.120[2]

long.IP.90 # 207.9889
```

```
## [1] 207.9889
```

```
long.IP.120 # 218.1444
```

```
## [1] 218.1444
```

```
#####
#comparacion de las longitudes de los IP's con los IC's
#####
```

```
long.IC.90 # 49.56229
```

```
## [1] 49.56229
```

```
long.IP.90 # 207.9889
```

```
## [1] 207.9889
```

```
long.IC.120 # 82.36508
```

```
## [1] 82.36508
```

```
long.IP.120 # 218.1444
```

```
## [1] 218.1444
```

```
plot(tamano,horas,main="diagrama de dispersion
de horas vs. tamano")
abline(salida,col="red",lwd=2)

equis<-seq(from=20,to=120,by=5)
IC<-predict(salida,newdata=data.frame(tamano=equis),interval="confidence")
IP<-predict(salida,newdata=data.frame(tamano=equis),interval="prediction")
```


```

points(equis, IC[,3], type="l", col="coral", lty=2, lwd=2)
points(equis, IC[,2], type="l", col="coral", lty=2, lwd=2)

points(equis, IP[,3], type="l", col="brown", lty=2, lwd=2)
points(equis, IP[,2], type="l", col="brown", lty=2, lwd=2)

```

diagrama de dispersion de horas vs. tamaño



```

#####
#j) Regresion inversa
#####

xpredicho <- (394-coef(salida)[1])/coef(salida)[2]
n<-length(tamaño)
# para el intervalo de confianza
cuantil<-qt(1-0.05/2,df=(n-2))
ese<-summary(salida)$sigma #(es el estimador de sigma)
sumaxx<-sum((tamaño-mean(tamaño))^2)
sumaxx

```

```
## [1] 19800
```

```

# o tambien
var(tamaño)*(length(tamaño)-1)

```

```
## [1] 19800
```

```
lio<-ese^2/(coef(salida)[2])^2*(1 + 1/n + (394 - mean(horas))^2/((coef(salida)[2])^2*sumaxx))
```

```
#intervalo inverso
```

```
xpredicho - cuantil * sqrt(lio)
```

```
## (Intercept)
```

```
## 63.67516
```

```
xpredicho + cuantil * sqrt(lio)
```

```
## (Intercept)
```

```
## 122.1038
```