

ESTADISTICA II

INGENIERIA INFORMATICA, 3^{ER} Curso

27 - Junio - 2.006 Primera Parte - Test

Apellidos y Nombre:

D.N.I. :

Nota : En la realización de este examen sólo esta permitido utilizar calculadoras que, a lo sumo, tengan funciones estadísticas básicas. **No se pueden utilizar calculadoras programables.**

Existe una sólo respuesta correcta por pregunta.

Cada respuesta correcta se valorará con 1 punto y cada incorrecta con -1/3. Las preguntas no contestadas no se valoran. Si se marcan varias respuestas a la vez se considerará la pregunta no contestada.

El valor de esta primera parte del examen es de CINCO PUNTOS sobre diez.

Responder con letras mayúsculas y bolígrafo.

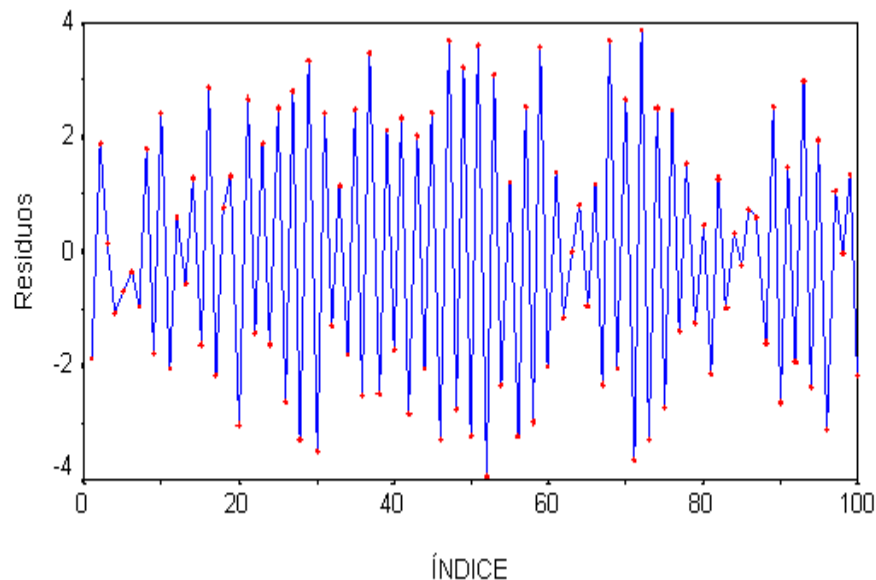
Las respuestas elegidas que se considerarán válidas son las que se consignent en el cuadro que se adjunta a continuación.

Pregunta	1	2	3	4	5	6
Respuesta	C	A	D	B	B	D
Pregunta	7	8	9	10	11	12
Respuesta	C	B	C	D	C	A

CUESTIONES

1. En el contraste de $H_0 : \theta = \theta_0$ frente a $H_1 : \theta = \theta_1$ se obtiene que $Potencia(\theta_0) = 0.06$. Entonces
 - A. La probabilidad de error de tipo 2 es 0.06
 - B. $P(aceptar H_0/\theta = \theta_1) = 0.94$
 - C. La probabilidad de error de tipo 1 es 0.06 **Solución**
 - D. $P(aceptar H_0/\theta = \theta_0) = 0.06$

2. En el ajuste de un modelo estadístico el gráfico de residuos frente al índice (orden de entrada de los datos) es el siguiente. En este gráfico se observa




- A. Que existe dependencia negativa. **Solución**
 B. Que existe dependencia positiva.
 C. Que existe independencia y homocedasticidad.
 D. Que existe independencia pero hay heterocedasticidad.
3. En el ajuste de un modelo estadístico, al hacer el contraste de Box-Ljung para las seis primeras autocorrelaciones ($m = 6$) de los residuos del modelo se obtiene un estadístico $Q_{BL} = 10$. Por tanto
- A. Se acepta que los residuos son independientes.
 B. Se acepta con $\alpha = 0.10$ que las seis primeras autocorrelaciones de los residuos son cero.
 C. Se rechaza que los residuos son independientes.
 D. Se acepta con $\alpha = 0.05$ que las seis primeras autocorrelaciones de los residuos son cero.

Solución

4. Sea \hat{F}_n la distribución empírica asociada a una muestra de tamaño n . Entonces $\hat{F}_n(x)$
- A. es una función escalonada con saltos iguales a x_i en los puntos $\frac{i}{n}$.
 B. igual a $\frac{n_i(x)}{n}$, siendo $n_i(x)$ el número de observaciones menores o iguales que x . **Solución**
 C. es igual a la recta $y = x$ en el gráfico de normalidad, bajo la hipótesis de normalidad.
 D. es igual a la distribución teórica a la muestra, $F(x)$, bajo la hipótesis de normalidad.

5. Para contrastar la igualdad de las medias de dos muestras independientes de igual varianza se utiliza el test de la t . El p – valor que se obtiene es
- A. Igual al que proporciona el test de la F en un diseño de experimentos con dos factores, uno fijo y uno aleatorio.
 - B. Igual al que proporciona el test de la F en un diseño de experimentos con un factor completamente aleatorizado. **Solución**
 - C. Igual al que proporciona el test de la F en un diseño de experimentos en bloques completamente aleatorizados.
 - D. Igual al que proporciona el test de la F en un diseño de experimentos con dos factores e interacción.
6. El contraste de Kruskal-Wallis se utiliza para contrastar
- A. Que los residuos de un diseño de experimentos con un factor son homocedásticos.
 - B. Que los residuos de un diseño de experimentos con un factor son heterocedásticos.
 - C. Que los residuos de un diseño de experimentos con un factor son independientes.
 - D. Que en un diseño de experimentos con un factor las medias de la respuesta condicionada a los niveles son iguales. **Solución**
7. Al ajustar un modelo de diseño de experimentos con un factor aleatorio: $Y_{ij} = \mu + \tau_i + \varepsilon_{ij}$, $i = 1, 2, 3, 4$, $j = 1, 2, \dots, 10$. Se ha obtenido que $scT = 252$ (Total) y $scR = 72$ (residual). Entonces la estimación de $Var(\tau_i) = \sigma_\tau^2$ es
- A. 4.92
 - B. 2.0
 - C. 5.8 **Solución**
 - D. Ninguna de las otras tres respuestas.
8. En el diseño de experimentos cuadrado latino, donde los factores tienen K niveles, el número de restricciones que verifican los residuos es
- A. $K^2 - 1$
 - B. $3K - 2$ **Solución**
 - C. $K^2 - 3K + 2$
 - D. Ninguna de las otras tres respuestas.
9. En el modelo de regresión lineal múltiple $\vec{Y} = X^t \vec{\alpha} + \vec{\varepsilon}$. Se verifica que
- A. el vector $H\vec{Y}$ es ortogonal a $\vec{\varepsilon}$
 - B. el vector $H\vec{Y}$ es ortogonal a $H\hat{Y}$
 - C. el vector $H\vec{Y}$ es ortogonal a $\vec{Y} - \hat{Y}$ **Solución**
 - D. el vector $H\vec{Y}$ es ortogonal a \hat{Y}

10. En el ajuste de un modelo de regresión lineal múltiple con dos regresoras, el gráfico de dispersión de las dos regresoras (x_1 y x_2) es el de la figura adjunta. De este gráfico se deduce
- A. El punto A es influyente y atípico.
 - B. El punto A es influyente a priori pero no a posteriori.
 - C. El punto A origina problemas de heterocedasticidad y falta de normalidad.
 - D. El punto A origina multicolinealidad entre las dos regresoras. **Solución**



11. En el modelo de regresión lineal simple, la hipótesis de linealidad afirma que

- A. $\hat{Y}_i = \alpha_0 + \alpha_1 x_i + \varepsilon_i$
- B. $E(Y_i/x_i) = \hat{\alpha}_0 + \hat{\alpha}_1 x_i$
- C. $E(Y_i/x_i) = \alpha_0 + \alpha_1 x_i$ **Solución**
- D. $Y_i = \hat{\alpha}_0 + \hat{\alpha}_1 x_i$

12. Al ajustar un modelo de regresión lineal múltiple con tres regresoras a una muestra de 40 observaciones, se ha obtenido que el estadístico del contraste conjunto de regresión es $\hat{F}_M = 10$. Entonces se obtiene que

- A. $R^2 = \frac{1}{2.2}$ **Solución**
- B. $R^2 = \frac{12}{23}$
- C. $R^2 = \frac{11}{36}$
- D. Ninguna de las otras tres respuestas.

ESTADISTICA II, Ingeniería Informática,

Problemas, 27 - Junio - 2.006

Apellidos, Nombre:

D.N.I.:

Responder de forma concisa y justificada a las siguientes cuestiones.

Las respuestas se escribirán con bolígrafo a continuación de las preguntas.

Cada una de las preguntas tiene una valoración máxima de 0.5 puntos sobre cinco.

Para aprobar el examen es necesario obtener una puntuación igual o superior a 1 punto en cada uno de los dos problemas.

Problema 1. *Para mejorar la velocidad de un procesador, se quiere saber el efecto, en el tiempo de realización de un determinado código, de la temperatura de funcionamiento (normal: 50°, alta: 70° o muy alta: 100°) y del tipo de circuito (C1, C2 y C3). Los resultados del experimento son los siguientes:*

		Factor C		
		C ₁	C ₂	C ₃
Factor T	T₁	0.62	0.34	0.35
		0.77	0.30	0.38
	T₂	0.55	0.50	0.55
		0.81	0.48	0.61
	T₃	0.6	0.52	0.62
		0.82	0.54	0.68

$\Sigma y_i = 10.04$

P.1. Formular el modelo de un diseño de experimentos con dos factores e interacción, y detallar todas las suposiciones que se hacen en él. Calcular las estimaciones de los efectos T, C e interacción.

Solución:

El modelo es $Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$, con ε_{ijk} v.a. independientes con distribución $N(0, \sigma^2)$.

Para estimar los parámetros, calculamos las medias en cada casilla, por filas y por columnas:

Medias				
\bar{y}_{ij}	C ₁	C ₂	C ₃	$\bar{y}_{i..}$
T ₁	0.695	0.32	0.365	0.46
T ₂	0.68	0.49	0.58	0.583
T ₃	0.71	0.53	0.65	0.63
$\bar{y}_{.j}$	0.695	0.447	0.528	$\bar{y}_{...} = \frac{10.04}{18} = 0.556$

Calculamos ahora los parámetros:

$$\hat{\alpha}_i = \bar{y}_{i..} - \bar{y}_{...}, \quad \hat{\beta}_j = \bar{y}_{.j.} - \bar{y}_{...}, \quad (\hat{\alpha\beta})_{ij} = \bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...}$$

Parámetros				
$(\hat{\alpha\beta})_{ij}$	C_1	C_2	C_3	$\hat{\alpha}_i$
T_1	0.096	-0.031	-0.067	-0.096
T_2	-0.042	0.016	0.025	0.027
T_3	-0.059	0.009	0.048	0.074
$\hat{\beta}_j$	0.139	-0.109	-0.028	

P.2. Completar la tabla ANOVA e indicar qué efectos que son significativos y cuáles no (nivel de significación 5%).

Solución:

Las sumas de cuadrados son:

$$\begin{aligned} VE(C) &= \Sigma\Sigma\Sigma\hat{\beta}_j^2 = 2 \times 3 \times (0.139^2 + 0.109^2 + 0.028^2) = 0.1911 \\ VE(T) &= \Sigma\Sigma\Sigma\hat{\alpha}_i^2 = 2 \times 3 \times (0.096^2 + 0.027^2 + 0.074^2) = 0.0926 \\ VR &= \Sigma e_{ijk}^2 = VG - VE(CT) - VE(C) - VE(T) \\ &= 0.4045 - 0.04629 - 0.1911 - 0.0926 = 0.0745 \end{aligned}$$

F. var.	sc	gl	SCM	F	p-valor	¿significativo?
Factor C	0.1911	2	0.0956	11.5	0.0033	SÍ
Factor T	0.0926	2	0.04629	5.59	0.0264	SÍ
Interacción	0.04629	4	0.01157	1.40	0.3096	NO
Residual	0.0745	9	0.00828			
Global	0.4045	17	0.02379			

P.3. Contrastar, con $\alpha = 0.05$, si el promedio de los efectos de los niveles C1 y C2 coincide con el efecto del nivel C3 del factor C.

Solución:

Las hipótesis a contrastar son

$$\begin{aligned} H_0 : \frac{1}{2}\beta_1 + \frac{1}{2}\beta_2 = \beta_3, \quad \text{es decir,} \quad H_0 : \theta = \frac{1}{2}\beta_1 + \frac{1}{2}\beta_2 - \beta_3 = \sum_{j=1}^{J=3} b_j\beta_j = 0 \\ H_1 : \frac{1}{2}\beta_1 + \frac{1}{2}\beta_2 \neq \beta_3, \quad H_1 : \theta = \frac{1}{2}\beta_1 + \frac{1}{2}\beta_2 - \beta_3 = \sum_{j=1}^{J=3} b_j\beta_j \neq 0 \end{aligned}$$

El estimador mínimo-cuadrático de θ es

$$\hat{\theta} = \sum_{j=1}^J b_j \hat{\beta}_j = \frac{1}{2} \hat{\beta}_1 + \frac{1}{2} \hat{\beta}_2 - \hat{\beta}_3 = \frac{1}{2} 0.139 - \frac{1}{2} 0.109 + 0.028 = 0.043 = \sum_{j=1}^J b_j \bar{y}_{.j}.$$

Sabiendo que

$$\hat{\theta} = \sum_{j=1}^J b_j \hat{\beta}_j \in N \left(\theta = \sum_{j=1}^J b_j \beta_j, \sigma^2 \sum_{j=1}^J \frac{b_j^2}{n_j} \right) \text{ entonces } \frac{\sum_{j=1}^J b_j \hat{\beta}_j - \sum_{j=1}^J b_j \beta_j}{\hat{s}_R \sqrt{\sum_{j=1}^J \frac{b_j^2}{n_j}}} \in t_{IJ(K-1)}$$

El valor del estadístico de contraste es

$$\frac{0.043}{\sqrt{0.00828} \sqrt{\frac{1}{6} + \frac{1}{6} + \frac{1}{6}}} = 0.94511$$

y por tanto el p -valor es


$$p\text{-valor} = 2P(t_9 \geq 0.94511) = 2 \times 0.184642 = 0.3693 \Rightarrow \text{Acepto } \mathbf{H}_0.$$

P.4. Dibujar el gráfico de interacciones poniendo en el eje de abscisas el factor T. Interpretar el resultado.

Solución:

Teniendo en cuenta la tabla de medias

Medias			
$\bar{y}_{ij.}$	C ₁	C ₂	C ₃
T ₁	0.695	0.32	0.365
T ₂	0.68	0.49	0.58
T ₃	0.71	0.53	0.65



P.5. Calcular la tabla ANOVA del modelo de dos factores sin interacción. En este caso ¿qué factores son significativos? Calcular el coeficiente de determinación de este modelo.

Solución:

F. var.	sc	gl	SCM	F	p-valor	¿significativo?
Factor C	0.1911	2	0.0956	10.29	0.0021	SÍ
Factor T	0.0926	2	0.04629	4.983	0.0248	SÍ
Residual	0.1208	13	0.00929			
Global	0.4045	17	0.02379			

No se puede eliminar ningún factor del análisis.

El coeficiente de determinación es

$$\begin{aligned}
 R^2 &= \frac{scE}{scG} = \frac{scE(C)}{scG} + \frac{scE(T)}{scG} \\
 &= \frac{0.1911}{0.4045} + \frac{0.0926}{0.4045} = 0.4724 + 0.2289 = \mathbf{0.70136}
 \end{aligned}$$

ESTADISTICA II, Ingeniería Informática,
Problemas, 27 - Junio - 2.006

Apellidos, Nombre:

D.N.I.:

Problema 2:

En base a una muestra de 22 observaciones se quiere estudiar la relación lineal que existe entre una variable respuesta (Y) y tres variables regresoras (X_1, X_2 y X_3). En una primera etapa se estudia la relación lineal simple entre la respuesta (Y) y una regresora (X_1). Se obtienen los siguientes datos

$$\begin{aligned} \sum_{i=1}^{22} x_{i1} &= 91 & \sum_{i=1}^{22} x_{i1}^2 &= 521 \\ \sum_{i=1}^{22} y_i &= -69 & \sum_{i=1}^{22} y_i^2 &= 1091 \\ \sum_{i=1}^{22} y_i \cdot x_{i1} &= 9'84 \end{aligned}$$

En todos los casos en que se pida estudiar la significatividad de un contraste utilizar $\alpha = 0'05$

P.6. Calcular la predicción para la observación muestral 22,
cuyos datos son: ($x_{22,1} = 10$; $y_{22} = 18$).

Solución:

$$\hat{\alpha}_1 = \frac{s_{1y}}{s_1^2} = \frac{13.42}{6.572} = 2.042$$

$$s_1^2 = \overline{x_1^2} - (\bar{x}_1)^2 = \frac{521}{22} - \left(\frac{91}{22}\right)^2 = 6.5723$$

$$s_1 = \sqrt{6.5723} = 2.5636$$

$$s_{1y} = \overline{x_1 \cdot y} - \bar{x}_1 \cdot \bar{y} = \frac{9.84}{22} - \frac{91}{22} \cdot \frac{-69}{22} = 13.42$$

$$\hat{\alpha}_0 = \bar{y} - \hat{\alpha}_1 \cdot \bar{x}_1 = \frac{-69}{22} - 2.042 \cdot \frac{91}{22} = -11.583$$

Por tanto la recta de regresión es:

$$\hat{Y} = -11.583 + 2.042 \cdot X_1$$

Y la predicción para la observación 22 es

$$\begin{aligned}\hat{y}_{22} &= -11.583 + 2.042 \cdot x_{22,1} = \\ &= -11.583 + 2.042 \cdot 10 = \mathbf{8.837}\end{aligned}$$

P.7. Utilizando el modelo de la cuestión anterior, estudiar si la observación muestral 22 es atípica y si es influyente a priori.

Solución:

El residuo ordinario es

$$e_{22} = y_{22} - \hat{y}_{22} = 18 - 8.837 = \mathbf{9.163}$$

El residuo estandarizado es

$$r_{22} = \frac{e_{22}}{\hat{s}_R \sqrt{1 - h_{22}}} = \frac{9.163}{3.80 \sqrt{1 - 0.283}} = \mathbf{2.8477}$$

Por tanto la observación 22 es atípica aunque no de forma exagerada.

Para el cálculo de \hat{s}_R se utiliza lo siguiente

$$\begin{aligned}\sum_{i=1}^{22} e_i^2 &= \sum_{i=1}^{22} y_i^2 - \left(\hat{\alpha}_0 \cdot \sum_{i=1}^{22} y_i + \hat{\alpha}_1 \cdot \sum_{i=1}^{22} y_i \cdot x_{i1} \right) \\ &= 1091 - (-11.583 \cdot (-69) + 2.042 \cdot 9'84) \\ &= \mathbf{288.77}\end{aligned}$$

$$\begin{aligned}\hat{s}_R^2 &= \frac{\sum_{i=1}^{22} e_i^2}{g.l.} = \frac{288.77}{20} = \mathbf{14.439} \\ \hat{s}_R &= \sqrt{14.439} = \mathbf{3.80}\end{aligned}$$

Se calcula el valor de influencia

$$\begin{aligned}h_{22} &= \frac{1}{n} \left(1 + \frac{(x_{22,1} - \bar{x}_1)^2}{s_1^2} \right) \\ &= \frac{1}{22} \left(1 + \frac{\left(10 - \frac{91}{22}\right)^2}{6.5723} \right) = \mathbf{0.28324} \\ n_{22} &= \frac{1}{h_{22}} = \frac{1}{0.28324} = 3.5306\end{aligned}$$

La media de los valores de influencia es

$$E(h) = \frac{k+1}{n} = \frac{2}{22} = 0.0909$$

Como $h_{22} = 0.28324 > 2 \cdot 0.0909 = 0.1818$, **la observación 22 es influyente a priori** (su $x_{22,1} = 10$ se separa claramente de la media $\bar{x}_1 = \frac{91}{22} = 4.1364$).

P.8. Utilizando el modelo de la cuestión anterior, estudiar el contraste de regresión e interpretarlo.

Solución:

El contraste de regresión es

$H_{0,reg}$: “el modelo de regresión lineal ajustado **no** es influyente” $\approx \alpha_1 = 0$

H_1 : “el modelo ajustado es influyente” $\approx \alpha_1 \neq 0$

El estadístico del contraste es \hat{d}_{reg}

$$\begin{aligned}\hat{d}_{reg} &= \frac{\hat{s}_e^2}{\hat{s}_R^2} = \frac{585.82}{14.439} = 40.572 \sim F_{1,20} \\ \Rightarrow \hat{d}_{reg} &= 40.572 > F_{1,20}(0.95) = 4.35\end{aligned}$$

:

Se rechaza $H_{0,reg}$, por tanto **el modelo es significativo.**

Se calcula \hat{s}_e^2

$$\hat{s}_e^2 = \frac{scE}{1} = \mathbf{585.82}$$

$$\begin{aligned}scE &= scG - scR = n \cdot s_Y^2 - scR \\ &= 22 \cdot 39.754 - 288.77 \\ &= 874.59 - 288.77 = \mathbf{585.82}\end{aligned}$$

$$s_Y^2 = \overline{y^2} - (\bar{y})^2 = \frac{1091}{22} - \left(\frac{-69}{22}\right)^2 = \mathbf{39.754}$$

Se **rechaza** $H_{0,reg}$ a un nivel del 0.05y se asume que el modelo ajustado es significativo.

P.9. *En una segunda etapa se estudia el modelo de regresión lineal múltiple con las tres variables regresoras, obteniendo el siguiente modelo ajustado*

$$\hat{Y} = -19.8 + 1.7 \cdot x_1 + 2.54 \cdot x_2 - 11.6 \cdot x_3$$

siendo para este modelo la suma de los residuos al cuadrado

$$\sum_{i=1}^{22} e_i^2 = 192$$

y la diagonal de la matriz $(X^t X)^{-1}$

$$diag(X^t X)^{-1} = \begin{pmatrix} 2.57 & & & \\ & 0.012 & & \\ & & 0.129 & \\ & & & 7.584 \end{pmatrix}$$

En base a estos datos estudiar qué regresoras son significativas.

Solución:

La varianza residual en este caso es

$$\hat{s}_R^2 = \frac{\sum_{i=1}^{22} e_i^2}{g.l.} = \frac{192}{18} = \mathbf{10.667}$$

$$Var(\hat{\alpha}) = \hat{s}_R^2 \cdot (X^t X)^{-1} \Rightarrow$$

$$Var(\hat{\alpha}_1) = \hat{s}_R^2 \cdot q_{11} = 10.667 \cdot 0.012 = 0.128 \Rightarrow \sigma(\hat{\alpha}_1) = \sqrt{0.128} = 0.3578$$

$$Var(\hat{\alpha}_2) = \hat{s}_R^2 \cdot q_{22} = 10.667 \cdot 0.129 = 1.376 \Rightarrow \sigma(\hat{\alpha}_1) = \sqrt{1.376} = 1.173$$

$$Var(\hat{\alpha}_3) = \hat{s}_R^2 \cdot q_{33} = 10.667 \cdot 7.584 = 80.899 \Rightarrow \sigma(\hat{\alpha}_1) = \sqrt{80.899} = 8.9944$$

Dado que $P(t_{18} > 2.10) = 0.025$ se obtiene finalmente

Parám (α_i)	Est ($\hat{\alpha}_i$)	$\sigma(\hat{\alpha}_i)$	$\hat{t}_i = \frac{\hat{\alpha}_i}{\sigma(\hat{\alpha}_i)}$	¿es significativa X_i ?
α_1	1.7	0.3578	$\frac{1.7}{0.3578} = 4.7513$	SI
α_2	2.54	1.173	$\frac{2.54}{1.173} = 2.1654$	SI
α_3	-11.6	2.7539	$\frac{-11.6}{2.7539} = -4.2124$	NO

P.10. Utilizando el modelo de la cuestión anterior, calcular la correlación parcial y simple entre las variables Y y X_1 .

Solución:

Coefficiente de correlación simple entre las variables Y y X_1

$$r_{Y1} = \frac{s_{Y1}}{s_1 \cdot s_Y} = \frac{13.42}{2.5636 \cdot \sqrt{39.754}} = \mathbf{0.83026}$$

Coefficiente de correlación parcial entre las variables Y y X_1

$$\begin{aligned} r_{y1.23}^2 &= \frac{\hat{t}_1^2}{\hat{t}_1^2 + n - (k + 1)} \\ &= \frac{4.7513^2}{4.7513^2 + 18} = 0.55638 \\ \Rightarrow r_{y1.23} &= \sqrt{0.55638} = \mathbf{0.74591} \end{aligned}$$