

## Solución Examen de Introducción a la Econometría

Universidad Carlos III de Madrid

2ª Convocatoria

Curso 2005/2006

**Conteste las preguntas siguientes en cuadernillos separados en 2 horas y media**

1. [2 puntos] Las desviaciones porcentuales sobre la tendencia de la renta agregada bruta disponible de las familias,  $Y_d$ , se descomponen en desviaciones del consumo agregado y del ahorro,  $Y_d = C + S$ . A partir de una muestra de tamaño  $n = 100$  de datos de series temporales, se obtienen los siguientes momentos muestrales:  $\hat{E}_n(C) = 1$ ,  $\hat{E}_n(Y_d) = 0,75$ ,  $\widehat{Cov}_n(Y_d, C) = 0,8$ ,  $\widehat{Var}_n(Y_d) = 1,2$ ,  $\widehat{Var}_n(S) = 2/3$ .

- a. [1 punto] Obtenga por el principio de analogía un estimador del predictor lineal óptimo del consumo agregado dada la renta disponible:

$$PLO[C|Y_d] = a_c + b_c Y_d$$

así como de la varianza del error de predicción,  $\sigma_c^2 = Var(C - b_c Y_d)$ .

- b. [0,5 puntos] Considere ahora la predicción del ahorro dada la renta disponible:

$$PLO[S|Y_d] = a_s + b_s Y_d$$

Demuestre que  $a_c + a_s = 0$ ,  $b_c + b_s = 1$ , y que  $\sigma_c^2 = \sigma_s^2$ .

- c. [0,5 puntos] Si le dan un valor de renta disponible, ¿qué variable preferiría predecir, el consumo o el ahorro? Justifique su respuesta.

**SOLUCIÓN: a.**

$$\begin{aligned} \hat{b}_c &= \frac{\widehat{Cov}_n(Y_d, C)}{\widehat{Var}_n(Y_d)} = \frac{0,8}{1,2} = \frac{2}{3} \\ \hat{a}_c &= \hat{E}_n(C) - \hat{b}_c \hat{E}_n(Y_d) = 1 - \frac{2}{3} * 0,75 = 0,5. \\ \hat{\sigma}_c^2 &= \widehat{Var}_n(C - b_c Y_d) = \widehat{Var}_n(C) (1 - R_c^2) \\ &= \frac{2}{3} \left( 1 - \frac{\widehat{Cov}_n(C, Y_d)^2}{\widehat{Var}_n(Y_d)} \right) = \frac{2}{3} \left( 1 - \frac{0,8^2}{1,2} \right) = 0,311. \\ R_c^2 &= \frac{\widehat{Cov}_n(C, Y_d)^2}{\widehat{Var}_n(C) \widehat{Var}_n(Y_d)}. \end{aligned}$$

$$\frac{2}{3} \left( 1 - \frac{0,8^2}{1,2} \right) = 0,31111$$

- b. Tenemos que si sumamos los modelos

$$\begin{aligned} C &= a_c + b_c Y_d + u_c \\ S &= a_s + b_s Y_d + u_s \end{aligned}$$

obtenemos

$$C + S = (a_c + a_s) + (b_c + b_s) Y_d + u_c + u_s$$

por lo que, usando que  $Y_d = C + S$ , se deduce que  $a_c + a_s = 0$ ,  $b_c + b_s = 1$ ,  $u_c = -u_s$  y por tanto  $\sigma_c^2 = \sigma_s^2$ .

- c. Habría que comparar, además del error absoluto,  $\sigma_c^2 = \sigma_s^2$ , el relativo de predicción, los  $R^2$  :

$$\begin{aligned} R_c^2 &= \frac{\widehat{Cov}_n(C, Y_d)^2}{\widehat{Var}_n(C)\widehat{Var}_n(Y_d)} = \frac{(0,8)^2}{1,0667 * 1,2} = 0,5 \\ R_s^2 &= \frac{\widehat{Cov}_n(S, Y_d)^2}{\widehat{Var}_n(S)\widehat{Var}_n(Y_d)} = \frac{(0,4)^2}{\frac{2}{3} * 1,2} = 0,2 \\ \widehat{Cov}_n(S, Y_d) &= \widehat{Var}_n(Y_d) - \widehat{Cov}_n(C, Y_d) \\ &= 1,2 - 0,8 = 0,4. \\ \widehat{Var}_n(C) &= \widehat{Var}_n(Y_d) + \widehat{Var}_n(S) - 2 * \widehat{Cov}_n(S, Y_d) \\ &= 1,2 + \frac{2}{3} - 2 * 0,4 = 1,0667 \end{aligned}$$

por lo que es *más* fácil predecir  $C$  que  $S$ , ya que  $C$  tiene más variabilidad y el error relativo de predicción es menor aunque el error absoluto,  $\sigma^2$ , sea igual de grande.

2. [2 puntos] Se quiere explicar la nota final obtenida en la selectividad, *selec*, en función de las horas semanales medias de estudio, *horas* y de la asignación a un programa de especial de ayuda al estudio, por medio de un modelo de regresión lineal

$$selec = \beta_0 + \beta_1 horas + \beta_2 prog + u \quad (1)$$

donde *prog* es una variable dummy de tal forma que  $prog_i = 1$  si el estudiante  $i$  es asignado al programa especial de ayuda al estudio.

- a. [0,5 puntos] Interprete los coeficientes del modelo (1). ¿Cuál sería la relación entre los coeficientes del modelo (1) y los del modelo lineal basado solamente en *horas*,

$$selec = \delta_0 + \delta_1 horas + v, \quad (2)$$

si se supone que la asignación al programa se ha efectuado aleatoriamente?

- b. [0,5 puntos] Si en cambio, se propusiese la asignación al programa favoreciendo a aquellos estudiantes con menor hábito de estudio, ¿cuál sería la relación esperada entre  $\beta_1$  y  $\delta_1$ ?
- c. [0,5 puntos] Explica como contrastarías la efectividad del programa de ayuda al estudio dada una muestra. Si sólo hay recursos para incluir a un 10% de los alumnos en el estudio, ¿qué política esperas que sea más efectiva para contrastar la efectividad del programa de ayuda al estudio, la asignación propuesta en (a) o la propuesta en (b)?
- d. [0,5 puntos] Se quiere modificar el modelo (1) para permitir que la efectividad de tiempo de estudio aumente con la inclusión en el programa. Proponga el modelo adecuado para ello e indique como contrastaría en dicho caso la existencia de un beneficio por la asignación al programa para los estudiantes que dedican 20 horas semanales a estudiar en media.

**SOLUCIÓN:** a.  $\beta_1$  indica el incremento medio en la nota de selectividad si se aumenta en una hora el tiempo de estudio a la semana, ceteris paribus, lo que implica no cambiar la asignación o no al programa de ayuda al estudio.  $\beta_0$  indica la nota media de un estudiante que no dedica ningún tiempo al estudio y no ha sido asignado al programa de ayuda.

Sabemos que en general

$$\delta_1 = \beta_1 + \beta_2 \frac{Cov(horas, prog)}{Var(horas)}, \quad (3)$$

pero si la asignación al programa de ayuda se efectúa aleatoriamente, entonces *prog* será independiente de *horas* (y de cualquier otra característica del estudiante), por lo que  $Cov(horas, prog) = 0$  y  $\delta_1 = \beta_1$ .

- b. Podemos esperar que  $\beta_1 > 0$  y que también  $\beta_2 > 0$ , con lo que dada la relación (3) y que la asignación al programa preferencial para estudiantes con *horas* por debajo de su media implica que  $Cov(horas, prog) < 0$ , tendremos que  $\delta_1 < \beta_1$ , es decir el modelo corto tiene un sesgo negativo e infraestima el efecto del tiempo de estudio sobre la nota de selectividad.

- c. Después de la estimación de MCO, la hipótesis nula a contrastar sería  $H_0 : \beta_2 = 0$  en contra de la alternativa  $H_1 : \beta_2 > 0$ , mediante un contraste de la  $t$ , rechazando  $H_0$  en favor de  $H_1$  si  $t$  es grande y positivo.

La efectividad del contraste va a ser mayor si podemos estimar con más precisión  $\beta_2$ . Si incluimos siempre al 10% de los estudiantes,  $prog$  es una variable Bernoulli con  $p = 0,1$  y por tanto  $Var(prog) = p(1-p) = 0,1 * 0,9 = 0,09$ , y su correspondiente suma de cuadrados,  $SST_{prog}$ , sería en ambos casos igual. En la situación de (a) tenemos que la varianza estimada del estimador  $\hat{\beta}_2$  es

$$\widehat{Var}(\hat{\beta}_2) = \frac{\hat{\sigma}^2}{n} \frac{1}{SST_{prog}},$$

porque da igual hacer la regresión corta que la larga, mientras que en (b) tenemos que

$$\widehat{Var}(\hat{\beta}_2) = \frac{\hat{\sigma}^2}{n} \frac{1}{SST_{prog} (1 - R_{horas,prog}^2)}$$

donde  $R_{horas,prog}^2$  es el coeficiente  $R^2$  de la regresión de  $prog$  sobre  $horas$ , que en este caso no es cero. Por tanto, si la asignación se hace como en (b), el estimador tendrá mayor varianza y el contraste será menos eficiente.

- d. En este caso hay que incluir una interacción:

$$selec = \beta_0 + \beta_1 horas + \beta_2 prog + \beta_3 horas * prog + \varepsilon,$$

donde el parámetro  $\beta_3$  recoge el retorno adicional medio de una hora extra de estudio para aquellos estudiantes que participan en el programa especial (con respecto a los que no participan). Los estudiantes que dedican 20 horas semanales por término medio tienen un beneficio esperado de ser incluidos en el programa (todo lo demás constante) de  $\beta_2 + \beta_3 * 20$ . Por tanto la hipótesis nula sería  $H_0 : \theta = 0$ , donde  $\theta = \beta_2 + \beta_3 * 20$ , y la alternativa sería  $H_1 : \theta > 0$ . Para efectuar el contraste habría que hacer un contraste unilateral de la  $t$ , donde para estimar  $\theta$  podríamos usar la estimación de  $\beta_2$  y  $\beta_3$  y sus errores estándar y covarianza para estimar el s.e. de  $\hat{\theta}$ . Alternativamente podríamos estimar directamente  $\theta$  mediante la ecuación

$$selec = \beta_0 + \beta_1 horas + \theta prog + \beta_3 (horas - 20) * prog + \varepsilon$$

al sustituir  $\beta_2 = \theta - 20\beta_3$ .

3. [3 puntos] Se dispone de una muestra de 550 empresas textiles y del sector automovilístico con información sobre el valor de su producción  $Y$  (en millones de euros), las unidades de trabajo empleadas  $N$  (en miles de horas trabajadas) y las unidades de capital utilizado en la producción  $K$ . También se tiene una variable,  $textil$ , que toma valor 1 si la empresa pertenece al sector textil y cero si pertenece al sector automovilístico. Se supone que la función de producción de las empresas es una Cobb-Douglas (es decir,  $Y_i = AN_i^{\beta_1} K_i^{\beta_2} e^{U_i}$ ); aplicando logaritmos se obtiene una versión lineal de esta función de producción  $\ln Y_i = \ln A + \beta_1 \ln N_i + \beta_2 \ln K_i + U_i$ . Por tanto, se han estimado los siguientes modelos por Mínimos Cuadrados Ordinarios:

$$\widehat{\ln Y_i} = -0,5241 + 0,7366 \ln N_i + 0,4453 \ln K_i \tag{4}$$

(0,6601) (0,1391) (0,0731)

$$n = 550 \quad R^2 = 0,1225 \quad SSR = 541,4375$$

$$\widehat{\ln Y_i} = 0,6514 - 1,9003 \textit{textil} + 0,5334 \ln N_i + 0,3321 \ln K_i + 0,3904 \textit{textil} * \ln N_i + 0,1214 \textit{textil} * \ln K_i$$

(0,9505) (1,3059) (0,2003) (0,0950) (0,2747) (0,1492)

(5)

$$n = 550 \quad R^2 = 0,1565 \quad SSR = 520,4230$$

$$\ln(\widehat{Y}_i/N_i) = 0,0518 + 0,3846 \textit{ textil} + 0,3530 \ln(K_i/N_i) + 0,0164 \textit{ textil} * \ln(K_i/N_i) \quad (6)$$

$(0,0835) \quad (0,1097) \quad (0,0893) \quad (0,1387)$   
 $n = 550 \quad R^2 = 0,0949 \quad SSR = 524,2166$

$$\ln(\widehat{Y}_i/N_i) = 0,2884 + 0,4131 \ln(K_i/N_i) \quad (7)$$

$(0,0547) \quad (0,0683)$   
 $n = 550 \quad R^2 = 0,0625 \quad SSR = 542,9477$

$$\widehat{Y}_i = 2,7303 - 4,3011 \textit{ textil} + 0,1854 \ln(K_i/N_i) + 0,6809 \textit{ textil} * \ln N_i + 0,3889 (\textit{ textil} * \ln K_i + \ln N_i) \quad (8)$$

$(0,5205) \quad (0,9312) \quad (0,0770) \quad (0,2525) \quad (0,1089)$   
 $n = 550 \quad R^2 = 0,1460 \quad SSR = 526,9304$

- a. [0,75 puntos] Suponga inicialmente que creemos que los parámetros de la función de producción son iguales en ambos sectores industriales. Contraste con un nivel de significación del 5% la hipótesis de que existen rendimientos constantes a escala.
- b. [0,75 puntos] Ahora suponga por contra que creemos que existen rendimientos constantes a escala. Contraste con un nivel de significación del 5% la hipótesis de que las funciones de producción son iguales en ambos sectores.
- c. [1 punto] Contraste con un nivel de significación del 5% la hipótesis conjunta de que en ambos sectores existen rendimientos constantes a escala (aunque los parámetros de las funciones de producción son diferentes).
- d. [0,5 puntos] Un experto industrial afirma que si una empresa del sector automovilístico aumenta las unidades de capital utilizadas en un 2% y además las unidades de trabajo empleadas en un 1% entonces el cambio (porcentual) en su producción será, en promedio, el mismo que el de una empresa textil que aumenta las unidades de capital utilizadas en un 1% y mantiene el trabajo constante. Contraste con un nivel de significación del 5% si existe evidencia empírica a favor de la aseveración del experto.

**SOLUCIÓN:** a. La función de producción es igual en ambos sectores,  $\ln Y_i = \beta_0 + \beta_1 \ln N_i + \beta_2 \ln K_i + U_i$ , donde los parámetros  $\beta_0$ ,  $\beta_1$  y  $\beta_2$  son iguales. La hipótesis de rendimientos constantes a escala se expresa en función de los parámetros como

$$H_0 : \beta_1 + \beta_2 = 1 \quad vs. \quad H_1 : \beta_1 + \beta_2 \neq 1$$

Imponiendo esta restricción, se tiene un modelo restringido  $\ln Y_i = \beta_0 + (1 - \beta_2) \ln N_i + \beta_2 \ln K_i + U_i$ , que reescribiendo y utilizando las propiedades de los logaritmos queda:  $\ln(Y_i/N_i) = \beta_0 + \beta_2 \ln(K_i/N_i) + U_i$ . Por tanto, el modelo sin restringir en este contexto se correspondería con la estimación (4) y el modelo restringido con (7). El estadístico de contraste es

$$W = qF = \frac{SSR_R - SSR_{SR}}{(SSR_{SR})/n} \underset{H_0}{\overset{a}{\sim}} \chi^2_{(q)}$$

En este caso  $q = 1$  y el estadístico tiene valor  $W = \frac{542,9477 - 541,4375}{541,4375/550} = 1,5341$ . El valor crítico de una  $\chi^2_{(1)}$  al 5% es  $c_{0,05}^* = 3,84$ . Puesto que  $W < c_{0,05}^*$  no evidencia empírica para rechazar la hipótesis nula al 5%.

- b. En este caso suponemos que existen rendimientos constantes a escala. Si se permite que los parámetros sean diferentes entre sectores, el modelo a estimar sería:  $\ln(Y_i/N_i) = \beta_0 + \delta_0 \textit{ textil} +$

$\beta_2 \ln(K_i/N_i) + \delta_2 \text{textil} * \ln(K_i/N_i) + U_i$ , donde  $\delta_0$  y  $\delta_2$  representan el diferencial en la constante y en la pendiente, respectivamente, entre el sector textil y el automovilístico. En el modelo restringido, no existe ninguna diferencia entre sectores, es decir,

$$H_0 : \delta_0 = \delta_2 = 0 \quad \text{vs.} \quad H_1 : H_0 \text{ no es cierta}$$

El modelo sin restringir en este contexto se correspondería con la estimación (6) y el modelo restringido con (7). En este caso,  $q = 2$  y el estadístico de contraste se puede calcular como

$$\begin{aligned} W = qF &= \frac{SSR_R - SSR_{SR}}{(SSR_{SR})/n} = \frac{R_{SR}^2 - R_R^2}{(1 - R_{SR}^2)/n} \\ &= \frac{542,9477 - 524,2166}{(524,2166)/550} \simeq \frac{0,0949 - 0,0625}{(1 - 0,0949)/550} \simeq 19,7 \end{aligned}$$

El valor crítico para una  $\chi_{(2)}^2$  al 5% es  $c_{0,05}^* = 5,99$ . Por tanto, existe evidencia empírica para rechazar la hipótesis nula al 5%. ( $W > c_{0,05}^*$ )

- c. El modelo más general (los parámetros pueden ser diferentes entre sectores y no se impone rendimientos constantes) sería

$$\ln(Y_i) = \beta_0 + \delta_0 \text{textil} + \beta_1 \ln(N_i) + \delta_1 \text{textil} * \ln(N_i) + \beta_2 \ln(K_i) + \delta_2 \text{textil} * \ln(K_i) + U_i$$

Esto se corresponde con el modelo (5). Si existen rendimientos constantes a escala en el sector automovilístico  $\beta_1 + \beta_2 = 1$ ; mientras que si existen rendimientos constantes a escala en el sector textil:  $(\beta_1 + \delta_1) + (\beta_2 + \delta_2) = 1$ . Nótese que si ambas condiciones se tienen que dar **conjuntamente**, la hipótesis nula será

$$H_0 : \begin{matrix} \beta_1 + \beta_2 = 1 \\ \delta_1 + \delta_2 = 0 \end{matrix} \quad \text{vs.} \quad H_1 : H_0 \text{ no es cierta}$$

El modelo restringido que ha incorporado estas restricciones es (6). Por tanto, el estadístico de contraste sería:

$$W = qF = \frac{SSR_R - SSR_{SR}}{(SSR_{SR})/n} = \frac{524,2166 - 520,4230}{(520,4230)/550} \simeq 4,0092$$

Puesto que  $q = 2$ , tenemos que compararlo con el valor crítico al 5% de una  $\chi_{(2)}^2$ :  $c_{0,05}^* = 5,99$ . Por tanto, no se puede rechazar la hipótesis nula ( $W < c_{0,05}^*$ ).

- d. Utilizando el modelo más general, los cambios en la producción ante cambios en los factores serían:

$$\text{en el sector automovilístico, } \Delta \ln(Y_i) = \beta_1 \Delta \ln(N_i) + \beta_2 \Delta \ln(K_i)$$

$$\text{en el sector textil, } \Delta \ln(Y_i) = (\beta_1 + \delta_1) \Delta \ln(N_i) + (\beta_2 + \delta_2) \Delta \ln(K_i)$$

Por tanto, en el sector automovilístico aumenta las unidades de capital utilizadas en un 2% y además las unidades de trabajo empleadas en un 1% aumentaría la producción en  $\Delta \ln(Y_i) = \beta_1 * 1 + \beta_2 * 2$ ; mientras que aumentar el capital en un 1% en una empresa textil supone un cambio en la producción de  $\Delta \ln(Y_i) = (\beta_2 + \delta_2) * 1$ . El enunciado dice que estos dos cambios son iguales, luego la hipótesis a contrastar es

$$H_0 : \beta_1 + 2\beta_2 = \beta_2 + \delta_2 \quad \text{vs.} \quad H_1 : \beta_1 + 2\beta_2 \neq \beta_2 + \delta_2$$

Si imponemos esta restricción (utilizando que  $\beta_1 = \delta_2 - \beta_2$ ), se tendría el modelo (8). Por tanto, el estadístico de contraste sería:

$$W = qF = \frac{SSR_R - SSR_{SR}}{(SSR_{SR})/n} = \frac{526,9304 - 520,4230}{(520,4230)/550} \simeq 6,8772$$

Puesto que  $q = 1$ , tenemos que compararlo con el valor crítico al 5% de una  $\chi_{(1)}^2$ :  $c_{0,05}^* = 3,84$ . Por tanto, hay evidencia empírica para rechazar la hipótesis nula al 5% ( $W > c_{0,05}^*$ ).

4. [3 puntos] Una empresa multinacional ha sido acusada de discriminar a sus empleadas pagándoles salarios menores que a los empleados. El presidente solicita una muestra aleatoria simple de 250 empleados y empleadas, todos/as con la misma experiencia y años de educación. En la muestra, se disponen de las siguientes variables:

$$\begin{aligned} \text{salario}_i &= \text{salario mensual del empleado/a } i \text{ (en euros)} \\ \text{mujer}_i &= \begin{cases} 1 & \text{si el individuo } i \text{ es mujer} \\ 0 & \text{en caso contrario} \end{cases} \\ \text{directiv}_i &= \begin{cases} 1 & \text{si el individuo } i \text{ tiene un puesto de trabajo directivo (toma de decisiones)} \\ 0 & \text{en caso contrario} \end{cases} \end{aligned}$$

A partir de esa muestra, el presidente obtiene la siguiente tabla con medias de los salarios para hombres y mujeres (y errores estándar de las respectivas medias entre paréntesis):

Tabla 1

Hombres	Mujeres
1915,57 (49,53)	2132,93 (79,91)

Algunos trabajadores, que estudiaron y comprendieron los conceptos básicos de la Econometría, no están satisfechos con esta evidencia. Solicitan la misma muestra y, a partir de ella, estiman varios modelos econométricos por Mínimos Cuadrados Ordinarios; como el presidente no los entiende muy bien, confeccionan la siguiente la tabla con medias de salarios (y errores estándar de las respectivas medias entre paréntesis):

Tabla 2

	Hombres	Mujeres
En trabajos directivos	2994,43 (9,22)	2497,97 (9,71)
En trabajos no directivos	1501,87 (6,34)	992,16 (18,98)

- a. [0,75 puntos] Formule un modelo econométrico (incluyendo las variables disponibles en la encuesta y/o variables construidas a partir de ellas) tal que uno de los parámetros pueda interpretarse como la diferencia en el salario promedio entre hombres y mujeres. Utilizando los datos de la Tabla 1, ofrezca valores para la estimación de todos los parámetros en este modelo.
- b. [0,75 puntos] Formule otro modelo econométrico (incluyendo las variables disponibles en la encuesta y/o variables construidas a partir de ellas) tal que uno de los parámetros pueda interpretarse como la diferencia en el salario promedio entre hombres en puestos directivos y mujeres en puestos directivos. Utilizando los datos de la Tabla 2, ofrezca valores para la estimación de todos los parámetros en este nuevo modelo.
- c. [0,5 puntos] A partir del modelo formulado en el apartado (a) y de los datos de la Tabla 1, contraste con un nivel de significación del 5% la hipótesis de que los hombres y las mujeres tienen el mismo salario.  
 [Pista: puesto que se utiliza una muestra aleatoria simple, la covarianza (condicional en educación y experiencia) entre el salario medio de un hombre y el salario medio de una mujer es, *ceteris paribus*, cero. Es decir, si  $\bar{y}^h$  e  $\bar{y}^m$  son el salario medio, *ceteris paribus*, de un hombre y de una mujer respectivamente, entonces  $Cov(\bar{y}^h, \bar{y}^m) = 0$  (donde  $Cov(\cdot)$  debe entenderse como covarianza condicional en educación y experiencia)]
- d. [0,5 puntos] A partir del modelo formulado en el apartado (b) y de los datos de la Tabla 2, contraste con un nivel de significación del 5% la hipótesis de que los hombres en puestos directivos y las mujeres en puestos directivos tienen el mismo salario.  
 [Pista: igual que en el apartado anterior, si  $\bar{y}^{hd}$ ,  $\bar{y}^{md}$ ,  $\bar{y}^{hn}$  e  $\bar{y}^{mn}$  son los salarios medio de hombre directivos, mujeres directivas, hombres no directivos y mujeres no directivas, respectivamente, entonces  $Cov(\bar{y}^{md}, \bar{y}^{mn}) = Cov(\bar{y}^{md}, \bar{y}^{hd}) = Cov(\bar{y}^{md}, \bar{y}^{hn}) = Cov(\bar{y}^{mn}, \bar{y}^{hd}) = Cov(\bar{y}^{mn}, \bar{y}^{hn}) = Cov(\bar{y}^{hd}, \bar{y}^{hn}) = 0$  ]

- e. [0,5 puntos] Contraste con un nivel de significación del 5% la hipótesis de que los diferenciales salariales entre hombres y mujeres no cambian según el tipo de trabajo; es decir, que la diferencia en el salario promedio entre hombres directivos y mujeres directivas es la misma que la diferencia en el salario promedio entre hombres no directivos y mujeres no directivas.

**SOLUCIÓN:** a. El modelo econométrico sería

$$\text{salario}_i = \delta_0 + \delta_1 \text{mujer}_i + u_i,$$

donde  $\delta_0$  sería el salario esperado de los hombres y  $(\delta_0 + \delta_1)$  el salario esperado de las mujeres; por tanto,  $\delta_1$  es la diferencia entre el salario esperado entre hombres y mujeres.

A partir de los datos de la Tabla 1, podemos concluir que  $\bar{y}^h = \hat{\delta}_0 = 1915,57$  y, como  $\bar{y}^m = \hat{\delta}_0 + \hat{\delta}_1 = 2132,93$ , la estimación del parámetro  $\delta_1$  será

$$\hat{\delta}_1 = 2132,93 - 1915,57 = 217,36$$

- b. Construyamos las variables dummies  $md_i = \text{mujer}_i * \text{directiv}_i$ ,  $mnd_i = \text{mujer}_i * (1 - \text{directiv}_i)$ ,  $hd_i = (1 - \text{mujer}_i) * \text{directiv}_i$ ,  $hnd_i = (1 - \text{mujer}_i) * (1 - \text{directiv}_i)$ . El modelo econométrico podría ser

$$\text{salario}_i = \beta_0 + \beta_1 md_i + \beta_2 mnd_i + \beta_3 hnd_i + \varepsilon_i$$

(aunque también podría haberse omitido la dummy de  $md_i$  en lugar de  $hd_i$ , obteniéndose también que el parámetro asociado a  $hd_i$  tiene la interpretación del diferencial requerido pero con el signo contrario). Utilizando los resultados de la Tabla 2 es fácil comprobar que los salarios medios estimados son:

$$\begin{aligned} \widehat{E}_n(\text{salario}_i | \text{hombre, directivo}) &= \bar{y}^{hd} = \hat{\beta}_0 = 2994,43 \\ \widehat{E}_n(\text{salario}_i | \text{mujer, directivo}) &= \bar{y}^{md} = \hat{\beta}_0 + \hat{\beta}_1 = 2497,97 \\ \widehat{E}_n(\text{salario}_i | \text{hombre, no directivo}) &= \bar{y}^{hn} = \hat{\beta}_0 + \hat{\beta}_3 = 1501,87 \\ \widehat{E}_n(\text{salario}_i | \text{mujer, no directivo}) &= \bar{y}^{mn} = \hat{\beta}_0 + \hat{\beta}_2 = 992,16 \end{aligned}$$

de donde es fácil despejar  $\hat{\beta}_1 = -496,46$ ;  $\hat{\beta}_2 = -2002,27$ ;  $\hat{\beta}_3 = -1492,56$

- c. La hipótesis nula es  $H_0 : \delta_1 = 0$  y el estadístico de este contraste será

$$t = \frac{\hat{\delta}_1}{se(\hat{\delta}_1)} \stackrel{a}{\underset{H_0}{\sim}} N(0,1)$$

para lo cual necesitamos calcular  $se(\hat{\delta}_1)$ ; hay que notar que  $\widehat{V}_n(\hat{\delta}_1) = \widehat{V}_n(\bar{y}^m - \bar{y}^h) = \widehat{V}_n(\bar{y}^m) + \widehat{V}_n(\bar{y}^h) - 2\widehat{C}_n(\bar{y}^m, \bar{y}^h)$ . A partir de la Tabla 1 y de la pista podemos obtener el valor de estas varianzas y covarianza muestrales:  $\widehat{V}_n(\hat{\delta}_1) = (79,91)^2 + (49,53)^2 - 0 = 8838,8$ . Por tanto,

$$t = \frac{217,36}{\sqrt{8838,8}} = 2,3120$$

Para una hipótesis alternativa bilateral, el valor crítico al 5% es  $c_{0,05}^* = 1,96$ ; puesto que  $|t| > c_{0,05}^*$  se rechaza la hipótesis nula de que hombres y mujeres tengan el mismo salario. De hecho, la evidencia empírica indicaría que *las mujeres ganan más*.

- d. La hipótesis nula es  $H_0 : \beta_1 = 0$  y el estadístico de este contraste será  $t = \frac{\hat{\beta}_1}{se(\hat{\beta}_1)} \stackrel{a}{\underset{H_0}{\sim}} N(0,1)$ . Nuevamente para calcular  $se(\hat{\beta}_1)$ , se utiliza que  $\widehat{V}_n(\hat{\beta}_1) = \widehat{V}_n(\bar{y}^{md} - \bar{y}^{hd}) = \widehat{V}_n(\bar{y}^{md}) + \widehat{V}_n(\bar{y}^{hd}) - 2\widehat{C}_n(\bar{y}^{md}, \bar{y}^{hd})$ . A partir de la Tabla 2 y de la pista podemos obtener el valor de estas varianzas y covarianza muestrales:  $\widehat{V}_n(\hat{\beta}_1) = (9,71)^2 + (9,22)^2 - 0 = 179,29$ . Por tanto,

$$t = \frac{-496,46}{\sqrt{179,29}} = -37,077$$

Existe una fuerte evidencia empírica para rechazar la hipótesis nula de que hombres directivos y mujeres directivas ganan lo mismo  $|t| > c_{0,05}^*$ . En este caso, la evidencia empírica indicaría que las mujeres directivas *ganan menos* una vez que se ha controlado por el tipo de puesto de trabajo.

e. El diferencial entre hombres directivos y mujeres directivas es

$$\beta_1 = E(\text{salario}_i | md_i = 1, hnd_i = mnd_i = 0, hd_i = 0) - E(\text{salario}_i | md_i = hnd_i = mnd_i = 0, hd_i = 1)$$

mientras que el diferencial entre hombres no directivos y mujeres no directivas es

$$\begin{aligned} & E(\text{salario}_i | md_i = 0, mnd_i = 1, hnd_i = 0, hd_i = 0) - E(\text{salario}_i | md_i = 0, mnd_i = 0, hnd_i = 1, hd_i = 0) \\ &= (\beta_0 + \beta_2) - (\beta_0 + \beta_3) = \beta_2 - \beta_3. \end{aligned}$$

El enunciado establece que ambos diferenciales son iguales, es decir, la hipótesis a contrastar y el correspondiente estadístico de contraste son:

$$H_0 : \beta_1 = \beta_2 - \beta_3 \quad \text{vs.} \quad H_1 : \beta_1 \neq \beta_2 - \beta_3$$

$$t = \frac{\hat{\beta}_1 - \hat{\beta}_2 + \hat{\beta}_3}{se(\hat{\beta}_1 - \hat{\beta}_2 + \hat{\beta}_3)} \stackrel{a}{\underset{H_0}{\sim}} N(0, 1)$$

Para el cálculo del error estándar utilizamos que  $\hat{V}_n(\hat{\beta}_1 - \hat{\beta}_2 + \hat{\beta}_3) = \hat{V}_n[(\bar{y}^{md} - \bar{y}^{hd}) - (\bar{y}^{mn} - \bar{y}^{hn})]$ ; puesto que todas las covarianzas son cero  $\hat{V}_n(\hat{\beta}_1 - \hat{\beta}_2 + \hat{\beta}_3) = \hat{V}_n(\bar{y}^{md}) + \hat{V}_n(\bar{y}^{hd}) + \hat{V}_n(\bar{y}^{mn}) + \hat{V}_n(\bar{y}^{hn}) = (9, 71)^2 + (9, 22)^2 + (18, 98)^2 + (6, 34)^2 = 579, 73$ . El valor del estadístico es

$$t = \frac{-496, 46 - (-2002, 27) + (-1492, 56)}{\sqrt{579, 73}} = 0, 5503$$

En conclusión, puesto que  $|t| = 0, 5503 < c_{0,05}^* = 1, 96$  no existe evidencia empírica para rechazar la hipótesis nula.

VALORES CRÍTICOS:

$N(0, 1)$
$\Pr(N(0, 1) > 2, 576) = 0, 005$
$\Pr(N(0, 1) > 2, 326) = 0, 01$
$\Pr(N(0, 1) > 1, 960) = 0, 025$
$\Pr(N(0, 1) > 1, 645) = 0, 05$
$\Pr(N(0, 1) > 1, 282) = 0, 10$

$\chi_{(1)}^2$	$\chi_{(2)}^2$	$\chi_{(3)}^2$
$\Pr(\chi_{(1)}^2 > 6, 63) = 0, 01$	$\Pr(\chi_{(2)}^2 > 9, 21) = 0, 01$	$\Pr(\chi_{(3)}^2 > 11, 34) = 0, 01$
$\Pr(\chi_{(1)}^2 > 3, 84) = 0, 05$	$\Pr(\chi_{(2)}^2 > 5, 99) = 0, 05$	$\Pr(\chi_{(3)}^2 > 7, 81) = 0, 05$
$\Pr(\chi_{(1)}^2 > 2, 71) = 0, 10$	$\Pr(\chi_{(2)}^2 > 4, 61) = 0, 10$	$\Pr(\chi_{(3)}^2 > 6, 25) = 0, 10$

Recordamos que una  $t$  de Student con  $n$  grados de libertad se comporta como un  $N(0, 1)$  para  $n$  razonablemente grande ( $n > 30$ ). Por otro lado, una  $F$  de Fisher con  $q$  grados de libertad en el numerador y  $n$  grados de libertad en el denominador se comporta como una  $\chi_{(q)}^2/q$ .