

TRABAJO FINAL PARA ECONOMETRIA

FELIPE I. TAPPATA

RESUMEN. Este documento contiene la solución al trabajo final de la materia *Econometría* en la Universidad Torcuato Di Tella, tercer trimestre de 2025. El código usado fue entregado junto a este documento, y se puede encontrar también en el repositorio <https://github.com/felipetappata/metrics-final>. Las consignas originales (con pequeñas modificaciones que no alteran el significado) han sido reproducidas dentro de cuadros intercalados con las soluciones para facilitar la lectura. El principal software usado es Julia, y $\text{\LaTeX}$ para la compilación de gráficos y tablas y del documento final. El archivo `README.md` en la raíz del repositorio contiene instrucciones para la replicación de los resultados. En el apéndice se encuentran reproducidos los *scripts* `ej1.jl`, `ej2.jl` y `ej3.jl`, que contienen el código necesario para replicar los ejercicios 1, 2.1 y 2.2 respectivamente.

1. PROPIEDADES DE MUESTRA FINITA DE FGLS (MCGE)

Ejercicio 1. Considere el modelo

$$y_i = \beta_0 + \beta_1 x_i + u_i, \quad i = 1, 2, \dots, 5N, \quad (1)$$

con $\beta_0 = -3$, $\beta_1 = 0.8$, $u_i \sim N(0, \Omega \otimes I_{N \times N})$, $\Omega = \text{diag}(4, 9, 16, 25, 36)$ y $x_i \sim U(1, 50)$.

1. Genere 5 000 muestras de $5N = 5$ observaciones de corte transversal a partir del modelo (1).
 - a) Para cada muestra estime por FGLS los parámetros del modelo y realice un test de hipótesis para contrastar que $H_0 : \beta_1 = 0.8$. Reporte tamaño del test al 1 % y 5 % y el poder del test cuando $\beta_1 = 0$ y $\beta_1 = 0.4$. Adicionalmente, reporte la media, mediana y desvío estándar de las estimaciones de β_0 y β_1 .
 - b) Utilice la descomposición de Cholesky para encontrar una matriz P que cumpla que se puede escribir a $\Omega = PP'$, aplique la transformación correspondiente a MCG al modelo (1) y estime el modelo por MCC y comente si cambia algún resultado.
2. Repita el punto anterior (solo el inciso a)) con $5N = 10$.
3. Repita el punto anterior (solo el inciso a)) con $5N = 30$.
4. Repita el punto anterior (solo el inciso a)) con $5N = 100$.
5. Repita el punto anterior (solo el inciso a)) con $5N = 200$.
6. Repita el punto anterior (solo el inciso a)) con $5N = 500$.
7. Describa detalladamente las propiedades de muestra finita de FGLS de acuerdo a lo que observó de los cuatro puntos anteriores. En especial, explique cómo cambia el tamaño y la potencia de los tests a medida que aumenta el tamaño de muestra.

1.1. El Modelo. Podemos escribir el modelo en forma matricial como

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{u}, \quad (2)$$

donde $\mathbf{Y} = (y_1, y_2, \dots, y_{5N})'$ es el vector de observaciones de la variable dependiente, $\mathbf{X}$ es la matriz de regresores

$$\mathbf{X} = \begin{bmatrix} X'_1 \\ X'_2 \\ \vdots \\ X'_{5N} \end{bmatrix} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_{5N} \end{bmatrix},$$

el vector de parámetros es $\beta = (\beta_0, \beta_1)'$ y el vector de errores es $\mathbf{u} = (u_1, u_2, \dots, u_{5N})'$. Tenemos observaciones i.i.d. de un regresor $x \sim U(1, 50)$ y, condicional en la matriz de datos los errores son independientes y normales con media cero, pero heterocedásticos:

$$\mathbf{u} | \mathbf{X} \sim N(0, \Omega \otimes I_{N \times N}).$$

Tenemos entonces

$$\begin{aligned} E[\mathbf{u} | \mathbf{X}] &= 0, \\ \text{var}[\mathbf{u} | \mathbf{X}] &= E[\mathbf{u}\mathbf{u}' | \mathbf{X}] = \Sigma := \Omega \otimes I_{N \times N} \end{aligned}$$

1.2. Mínimos Cuadrados Generalizados. Cuando Σ es conocida, el estimador de Aitken (1935),

$$\tilde{\beta}_{\text{gls}} = (\mathbf{X}'\Sigma^{-1}\mathbf{X})^{-1}\mathbf{X}'\Sigma^{-1}\mathbf{Y}, \quad (3)$$

es insesgado para β y es eficiente en la clase de estimadores insesgados (Hansen, 2022, pág. 108). Este estimador, $\tilde{\beta}_{\text{gls}}$, es el de *mínimos cuadrados generalizados* (GLS o MCG). El estimador GLS se puede entender como el resultado de estimar por mínimos cuadrados clásicos (OLS) a un modelo transformado, obtenido premultiplicando ambos lados del modelo (2) por $\Sigma^{-1/2}$,¹ obteniendo

$$\tilde{\mathbf{Y}} = \tilde{\mathbf{X}}\beta + \tilde{\mathbf{u}}, \quad (4)$$

donde $\tilde{\mathbf{Y}} = \Sigma^{-1/2}\mathbf{Y}$, $\tilde{\mathbf{X}} = \Sigma^{-1/2}\mathbf{X}$ y $\tilde{\mathbf{u}} = \Sigma^{-1/2}\mathbf{u}$. El estimador OLS es

$$\begin{aligned} \hat{\beta} &= (\tilde{\mathbf{X}}'\tilde{\mathbf{X}})^{-1}\tilde{\mathbf{X}}'\tilde{\mathbf{Y}} \\ &= ((\Sigma^{-1/2}\mathbf{X})'(\Sigma^{-1/2}\mathbf{X}))^{-1}(\Sigma^{-1/2}\mathbf{X})'(\Sigma^{-1/2}\mathbf{Y}) \\ &= (\mathbf{X}'\Sigma^{-1}\mathbf{X})^{-1}\mathbf{X}'\Sigma^{-1}\mathbf{Y}. \end{aligned}$$

Esta transformación es útil. Por un lado, nos permite establecer que bajo el modelo normal que hemos supuesto, el estimador GLS es el estimador de máxima verosimilitud (MLE) para β .² Más relevante para el ejercicio, nos permite establecer que la matriz mencionada por el inciso b) puede ser, tomando raíces cuadradas de los elementos de la diagonal de Ω , $P = \text{diag}(2, 3, 4, 5, 6)$, y por lo tanto

$$\Sigma^{-1/2} = \text{diag}(2, 3, 4, 5, 6) \otimes I_{N \times N}$$

Luego, la estimación “directa” de GLS es algebraicamente equivalente a la estimación de OLS del modelo transformado.³

¹La matriz $\Sigma^{-1/2}$ existe y es única para Σ positiva definida.

²El estimador OLS es algebraicamente equivalente al estimador de máxima verosimilitud en el modelo normal heterocedástico (Hansen, 2022, pág. 144). El error de nuestro modelo transformado se distribuye como $\tilde{\mathbf{u}} \sim N(0, I)$, y por lo tanto el modelo transformado es un modelo normal homocedástico y vale el resultado. También se puede derivar fácilmente de manera directa minimizando $\ell(\beta) = -(1/2)((\mathbf{Y} - \mathbf{X}\beta)' \Sigma^{-1}(\mathbf{Y} - \mathbf{X}\beta))$.

³Usaremos esto para responder el ejercicio b); las estimaciones del modelo transformado serán mejores que las del modelo original, porque estaremos comparando GLS con FGLS.

Notemos, por último, que en este modelo el estimador de GLS es también el de mínimos cuadrados ponderados (WLS), porque Σ es diagonal. Es decir, $\tilde{\beta}_{\text{glS}}$ es el argumento minimizador de

$$\min_b \sum_{i=1}^{5N} \sigma_i^{-2} (y_i - X_i' b)^2,$$

donde σ_i denota la varianza del error de la observación i .

En general, Σ es desconocida y por lo tanto la expresión (3) no constituye un estimador (no es función de la muestra), y decimos que no es estimable (es *infeasible*). Un estimador que reemplaza Σ en la ecuación (3) por una estimación consistente $\hat{\Sigma}$ se denomina un estimador de *mínimos cuadrados generalizados estimables* (FGLS o MCGE). Es decir, si $\hat{\Sigma}$ es un estimador consistente para Σ , definimos el estimador de FGLS como

$$\tilde{\beta}_{\text{fglS}} = (\mathbf{X}' \hat{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}' \hat{\Sigma}^{-1} \mathbf{Y}.$$

Los estimadores FGLS son asintóticamente equivalentes entre sí, y asintóticamente equivalentes al estimador de GLS. El estimador FGLS se puede entender también como OLS ponderado, como en la discusión previa. Mientras que GLS pondera a cada residuo por la inversa de la varianza de su correspondiente error, FGLS pondera por una estimación de dicha varianza:

$$\tilde{\beta}_{\text{fglS}} = \arg \min_{\beta} \sum_{i=1}^{5N} \hat{\sigma}_i^{-2} (y_i - X_i' \beta)^2,$$

1.3. Estimación de varianzas del error. Desde el punto de vista de estimación, asumiremos que la estructura del modelo es considerada correcta, o conocida, con parámetros β y Ω desconocidos. Esto quiere decir que, si bien hay heterocedasticidad y no se conocen los elementos de la matriz Σ , se conoce que Σ tiene la estructura $\Sigma = \Omega \otimes I_{N \times N}$, con Ω diagonal.⁴ Para estimar Σ , nos alcanza con estimar los cinco parámetros $\sigma_1^2, \sigma_2^2, \sigma_3^2, \sigma_4^2, \sigma_5^2$ que definen la matriz Ω . Podemos pensar a la muestra como 5 muestras de N observaciones independientes con errores heterocedásticos, a fines de estimar cada una de las varianzas σ_j^2 . Es decir, si bien todas las observaciones “llevan información” sobre los coeficientes β , cada bloque de N observaciones “lleva información” sobre una sola de las varianzas σ_j^2 .⁵

Los índices originales de la muestra, $i \in \{1, 2, \dots, 5N\}$, se pueden renombrar con un par (j, k) , donde $j \in \{1, 2, 3, 4, 5\}$ indica a qué bloque de N observaciones corresponde la observación i , y $k \in \{1, 2, \dots, N\}$ indica el número de la observación dentro del bloque de manera que $i = (j - 1)N + k$. Luego, dentro de cada bloque j ,

$$Y_{jk} = X'_{jk} \beta + u_{jk}, \quad u_{jk} \stackrel{\text{iid}}{\sim} N(0, \sigma_j^2),$$

lo cual sugiere la estimación de cada σ_j^2 por el estimador de varianza de los residuos de OLS en el bloque j :

$$\hat{\sigma}_j^2 = \frac{1}{N} \sum_{k=1}^N \hat{u}_{jk}^2,$$

⁴Esto es quizá ambiguo en la consigna original, pero si no asumimos nada sobre la estructura de Σ , salvo diagonalidad, entonces tenemos el problema de estimar $5N$ parámetros con solo $5N$ observaciones.

⁵A nivel intuitivo esto es claro, pero lo podemos formalizar más rigurosamente factorizando la función de verosimilitud conjunta de la muestra completa.

donde $\hat{u}_{jk} = Y_{jk} - X'_{jk}\hat{\beta}$ es el residuo de OLS para la observación k del bloque j .⁶

1.4. Test de hipótesis. Para contrastar la hipótesis nula $H_0 : \beta_1 = 0.8$, podemos usar el estadístico T definido como

$$T := \frac{\tilde{\beta}_{\text{fgls},1} - 0.8}{\sqrt{\widehat{\text{var}}(\tilde{\beta}_{\text{fgls},1})}}, \quad (5)$$

donde $\tilde{\beta}_{\text{fgls},1}$ es la componente de $\tilde{\beta}_{\text{fgls}}$ correspondiente a β_1 , y $\widehat{\text{var}}(\tilde{\beta}_{\text{fgls},1})$ es la estimación de la varianza de esta componente, que se obtiene como el elemento diagonal correspondiente a β_1 de la matriz $(\mathbf{X}'\hat{\Sigma}^{-1}\mathbf{X})^{-1}$. Bajo la hipótesis nula, la distribución asintótica de T es normal estándar:

$$T \xrightarrow{d} N(0, 1).$$

Por lo tanto, nos referiremos con *test de nivel o tamaño* α al test a dos colas que tiene nivel asintótico α ; más precisamente, región de rechazo

$$\mathcal{R} = \{T : |T| > z_{1-\alpha/2}\},$$

donde $z_{1-\alpha/2}$ es el cuantil $1 - \alpha/2$ de la distribución normal estándar.⁷

1.5. Experimento Monte Carlo. El experimento de Monte Carlo consiste en generar $B = 5\,000$ muestras de $5N$ observaciones a partir del modelo (2) con los parámetros y la estructura de varianza especificados, y para cada muestra estimar por FGLS los parámetros del modelo y realizar un test de hipótesis para contrastar que $H_0 : \beta_1 = 0.8$. En particular, realizamos un $B = 5\,000$ simulaciones para cada combinación de tamaño de muestra $5N \in \{5, 10, 30, 100, 200, 500\}$ y valor generador de datos $\beta_1 \in \{0, 0.4, 0.8\}$. Los gráficos se hacen en el loop, para no tener que guardar resultados en la memoria, pero los estadísticos de resumen (tasa de rechazo, media, mediana y desvío estándar de las estimaciones de β_0 y β_1) se guardan.

Para el inciso b), realizamos los mismos experimentos, pero la “estimación” por FGLS es en realidad OLS en el modelo transformado (4), i.e., GLS.

1.6. Implementaciones. El código para la resolución de este ejercicio se encuentra en el script `scripts/ej1.jl`. A seguir, una breve descripción de las funciones principales usadas.

- `draw_sample` genera una muestra de $5N$ observaciones a partir del modelo (2) con los parámetros y la estructura de varianza especificados. En la práctica, usamos la función `draw_sample!`, que funciona de la misma manera, pero muta sus argumentos *in-place* a fines de optimizar la ejecución de los experimentos de Monte Carlo.⁸

⁶El vector $\hat{\beta}$ es el estimador OLS usando todas las $5N$ observaciones, no solo las del bloque j . Una posible mejora sería iterar el proceso, recalculando $\hat{\beta}$ por FGLS usando las estimaciones de varianza obtenidas en la iteración previa, y luego recalculando las varianzas usando los residuos de esta nueva estimación de β , y así sucesivamente hasta convergencia. Otra mejora posible sería hacer un ajuste por muestra finita, teniendo en cuenta el *leverage* de un bloque sobre la estimación de $\hat{\beta}$.

⁷Es decir, z_a es el valor tal que $\mathbb{P}[Z \leq z_a] = a$ para $Z \sim N(0, 1)$. Para 1 % y 5 %, usamos valores críticos de 2.576 y 1.96, respectivamente.

⁸El signo de exclamación ‘!’ es una convención en Julia para indicar que la función muta sus argumentos. Otras funciones que usan esta notación son la que fija el `seed`, `Random.seed!(8869)` y la implementación del test de White en `scripts/ej2.jl`.

- `ols_2reg` estima por OLS los coeficientes de un modelo de regresión lineal simple (constante y pendiente) de manera muy eficiente, funcionando mediante sumas escalares en lugar de operaciones matriciales.
- `omega_hat_ols` estima la la matriz Ω usando el procedimiento descrito en la sección 1.3.
- `gls_given_omega` computa los coeficientes de GLS/FGLS según la ecuación (3) dado un valor para Ω . También devuelve los elementos diagonales de $(\mathbf{X}'\Sigma^{-1}\mathbf{X})^{-1}$, dado Ω , para calcular errores estándar para inferencia. Obviamente Ω puede ser la verdadera matriz o una estimación de ella.
- `fgl`s compone las dos funciones anteriores para estimar por FGLS, dado una muestra. También devuelve errores estándar para los parámetros.
- `t_test` construye el estadístico T de la ecuación (5).
- `run_exper` ejecuta un experimento de Monte Carlo. Esto es, dado la cantidad de simulaciones B , el tamaño de muestra $5N$, y los valores “verdaderos” (generadores de datos) de β_0 y β_1 (entre otros argumentos), genera B muestras a partir del modelo (2) con los parámetros y la estructura de varianza especificados, y para cada muestra estima por FGLS los parámetros del modelo y realiza un test de hipótesis para contrastar que $H_0 : \beta_1 = 0.8$.
- `run_monte_carlo` ejecuta `run_exper` para cada combinación de argumentos que requirimos para responder la consigna.

Hay otras funciones relacionadas con la creación y tablas que no son mencionadas en esta sección.

1.7. Resultados. El cuadro 1 muestra las tasas de rechazo empíricas (i.e., la frecuencia relativa de tests rechazados en las $B = 5\,000$ simulaciones) para el test de hipótesis propuesto para cada tamaño de muestra, y para valores generadores de datos $\beta_1 = 0$, $\beta_1 = 0.4$ y $\beta_1 = 0.8$. Las primeras cuatro columnas muestran la frecuencia relativa de rechazo de la

CUADRO 1. Tasas de rechazo empíricas

$5N$	$\beta_1 = 0$		$\beta_1 = 0.4$		$\beta_1 = 0.8$	
	1 %	5 %	1 %	5 %	1 %	5 %
5	98.4 %	99.08 %	86.4 %	90.92 %	37.48 %	47.44 %
10	99.96	99.98	96.56	98.24	20.68	31.76
30	100	100	100	100	5.28	12.7
100	100	100	100	100	1.7	7.26
200	100	100	100	100	1.36	5.58
500	100	100	100	100	1.24	5.5

hipótesis nula cuando el valor generador de datos no es el de la hipótesis nula: una estimación de la probabilidad de rechazar correctamente. Incluso en muestras pequeñas, el test exhibe potencia muy elevada en los dos parámetros presentados. Sin saber el contenido económico del parámetro β_1 , es difícil decir si esto es necesariamente bueno—puede ser el caso que por las unidades del modelo, la brecha entre $\beta_1 = 0.4$ y $\beta_1 = 0.8$ sea muy grande, y por lo tanto que no sea difícil distinguir entre ambos valores. Es decir, se valora la capacidad de un test para distinguir entre valores “cercaños” a la hipótesis nula, pero sin un contexto económico es difícil decir si 0.4 es un valor cercano a 0.8 o no. De todos modos, podríamos

decir tentativamente que la potencia del test es buena incluso en muestras pequeñas, al menos para los parámetros probados. Asintóticamente, la probabilidad de rechazar la hipótesis nula cuando el valor generador de datos no es el de la hipótesis nula es igual a uno, y podríamos decir que los valores exhibidos (e.g. 99.4 %, 98.24 %) son razonablemente cercanos a este valor asintótico, incluso para muestras pequeñas.

La última columna de la tabla 1, correspondiente a $\beta_1 = 0.8$, presenta la frecuencia relativa de rechazo de la hipótesis nula cuando el valor generador de datos coincide con el de hipótesis nula: una estimación de la probabilidad de rechazar incorrectamente. A diferencia con la potencia del test, aquí hay una clara discrepancia entre el valor asintótico y los valores empíricos en muestras de tamaño menor a $5N = 200$. Para $5N = 5$, el tamaño empírico (esto es, frecuencia relativa de rechazos bajo el proceso generador de datos de la hipótesis nula) para el test de tamaño nominal de 1 % es de 37.48 %, lo cual rinde inservible el test en este caso. Para el test de tamaño 5 %, también hay un tamaño empírico un orden de magnitud mayor al nominal. A medida que aumenta el tamaño de muestra, el tamaño empírico se acerca al nominal, pero incluso para $5N = 100$ la probabilidad (empírica) de rechazar incorrectamente la hipótesis nula es más de un 50 % mayor a la probabilidad nominal.

La diferencia del tamaño con su valor asintótico, y la convergencia a medida que crece el tamaño muestral, se puede apreciar mirando la figura 2, que muestra la distribución empírica del estadístico T bajo $H_0 : \beta_1 = 0.8$ para cada tamaño de muestra. En particular, los gráficos de esta figura muestran la distribución asintótica de T bajo H_0 (normal estándar, línea punteada) y un *kernel density estimate* (KDE, línea sólida), que es una estimación no paramétrica de la función de densidad de T bajo H_0 .⁹ Las áreas sombreadas en cada gráfico corresponden a la frecuencia relativa de rechazos empírica, es decir, el área debajo de la densidad empírica de T que cae en la región de rechazo del test. El valor de estas áreas se encuentran arriba y a la izquierda de cada gráfico, y corresponden a la anteúltima columna de la tabla 1. Vemos que para los tamaños más pequeños de $5N$, la distribución de T posee colas más pesadas que la distribución asintótica, lo cual sirve para explicar el tamaño empírico tan elevado. A medida que crece $5N$, la distribución empírica de T se acerca a la normal estándar, y por lo tanto el tamaño empírico se acerca al nominal.

La relación entre el valor de β_1 generador de datos, el tamaño de muestra y la tasa de rechazo empírica se puede ver de manera más completa en la figura 1. Cada punto de la figura corresponde a una combinación $(5N, \beta_1)$, y la intensidad de su color representa la tasa rechazo empírica de un test de tamaño nominal 5 % resultante de un experimento de Monte Carlo con $B = 10\,000$ replicaciones para esa combinación. Los puntos más oscuros corresponden a tasas de rechazo más bajas, y los puntos más claros a tasas de rechazo más altas. Considerando la figura 1, uno se puede dar una noción de qué valores de β_1 son “cercanos” a 0.8 y cuáles no, en el sentido de la capacidad del test para distinguir entre ellos.

El cuadro 4 muestra los estadísticos de resumen de las estimaciones de β_0 y β_1 obtenidas por FGLS en cada una de las $B = 5\,000$ simulaciones para cada tamaño de muestra. No ocurre nada fuera de lo esperable: a medida que aumenta el tamaño de la muestra, la media y la mediana de las estimaciones se acercan a los valores verdaderos, y el desvío estándar de las estimaciones disminuye.

⁹La implementación de KDE se puede ver en la función `plot_t_kde` del script `scripts/ej1.jl`. Se optó por un KDE en lugar de un histograma para ilustrar la distribución empírica de T porque el KDE es una función suave, lo cual facilita la comparación visual con la distribución asintótica. Para $5N = 5$, por ejemplo, solo aparecían dos “bins” en el intervalo mostrado en la figura 2a, lo cual no era muy útil.

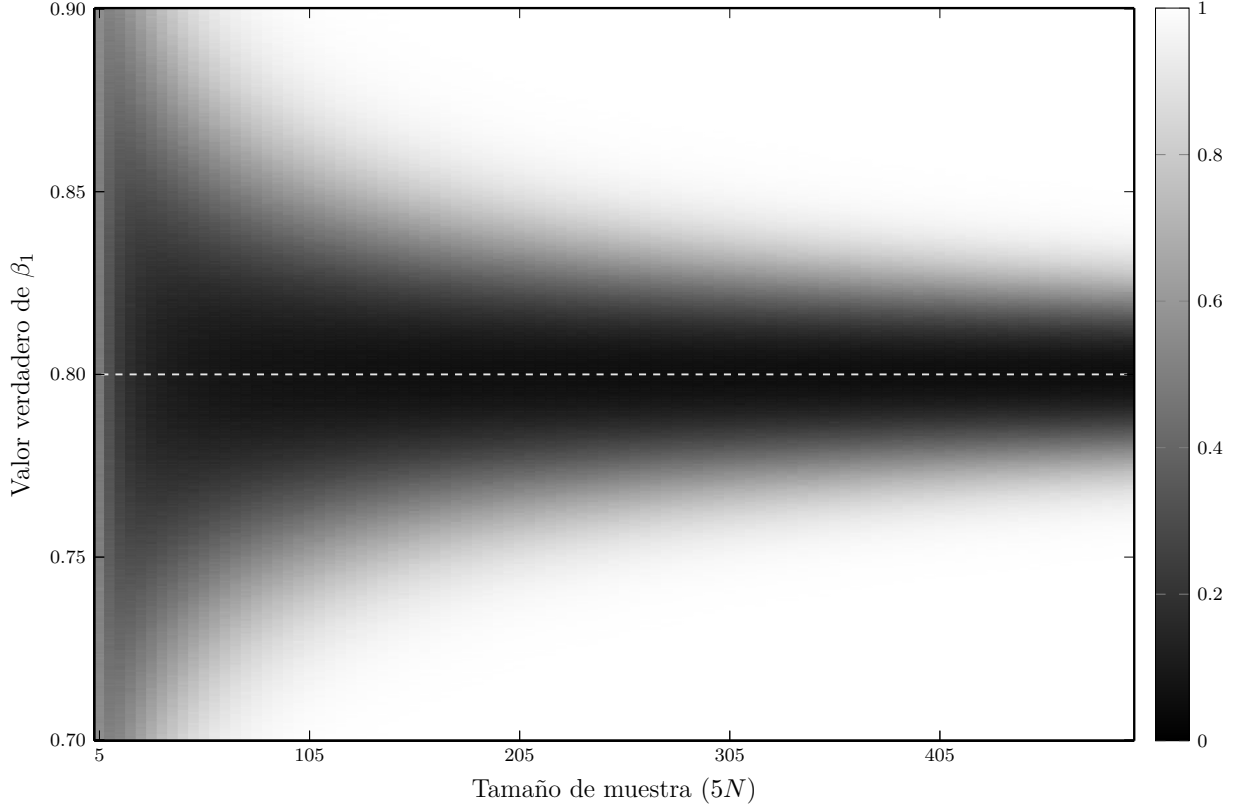


FIGURA 1. Relación entre tamaño de muestra, valor generador de datos y tasa de rechazo empírica

1.8. Comparación entre GLS y FGLS. Como mencionamos en la sección 1.2, la estimación del modelo transformado (4) por OLS es algebraicamente equivalente a la estimación de GLS del modelo original (2). Por lo tanto, comparar los resultados de la estimación de GLS con los de la estimación de FGLS es equivalente a comparar los resultados de la estimación por OLS del modelo transformado con los resultados de la estimación por FGLS del modelo original. La función `run_exper2` del script `scripts/ej1.jl` realiza $B = 5000$ simulaciones del modelo, lo transforma premultiplicando por $\Sigma^{-1/2}$, y estima por OLS el modelo transformado, obteniendo así estimaciones de GLS para cada simulación. En el cuadro 2 se muestran los estadísticos de resumen de las estimaciones de β_0 y β_1 obtenidas por GLS y FGLS en cada una de las $B = 5000$ simulaciones para cada tamaño de muestra. Podemos observar aquí la dinámica de convergencia en distribución del estimador FGLS al estimador GLS a medida que aumenta el tamaño de muestra. También podemos ver, tanto en la tabla 3 (que muestra las tasas de rechazo) como en la figura 3, que la distribución empírica bajo la hipótesis nula del estadístico T se acerca mucho más a la distribución asintótica (porque la *sampling distribution* de T es exactamente $N(0, 1)$ bajo GLS), y por lo tanto el tamaño empírico también se encuentra cerca de su valor asintótico para todo tamaño de muestra.

CUADRO 2. Estimación por GLS y FGLS

5N	FGLS				GLS			
	$\tilde{\beta}_0$		$\tilde{\beta}_1$		$\tilde{\beta}_0$		$\tilde{\beta}_1$	
	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana
5	-2.9051 (5.5342)	-2.8620	0.7965 (0.1967)	0.7956	-3.0228 (4.6455)	-2.9909	0.8011 (0.1660)	0.8021
10	-2.9697 (2.9882)	-2.9149	0.7983 (0.1047)	0.7967	-3.0127 (2.4693)	-2.9936	0.8003 (0.0858)	0.7991
30	-3.0070 (1.4067)	-3.0254	0.8001 (0.0483)	0.8013	-3.0147 (1.2645)	-3.0305	0.8001 (0.0437)	0.8003
100	-2.9960 (0.6922)	-3.0048	0.7994 (0.0238)	0.7996	-3.0168 (0.6695)	-3.0042	0.8006 (0.0229)	0.8009
200	-3.0038 (0.4709)	-3.0060	0.8001 (0.0162)	0.8002	-2.9985 (0.4751)	-2.9990	0.7998 (0.0162)	0.7998
500	-2.9997 (0.3002)	-3.0019	0.8002 (0.0103)	0.8002	-2.9993 (0.2979)	-2.9999	0.7999 (0.0102)	0.8000

CUADRO 3. Tasas de rechazo empíricas para GLS y FGLS

5N	FGLS		GLS	
	1 %	5 %	1 %	5 %
5	37.48 %	47.44 %	0.98 %	5.28 %
10	20.68	31.76	0.84	4.66
30	5.28	12.7	0.86	4.9
100	1.7	7.26	0.94	4.86
200	1.36	5.58	1.32	5.14
500	1.24	5.5	1.1	4.94

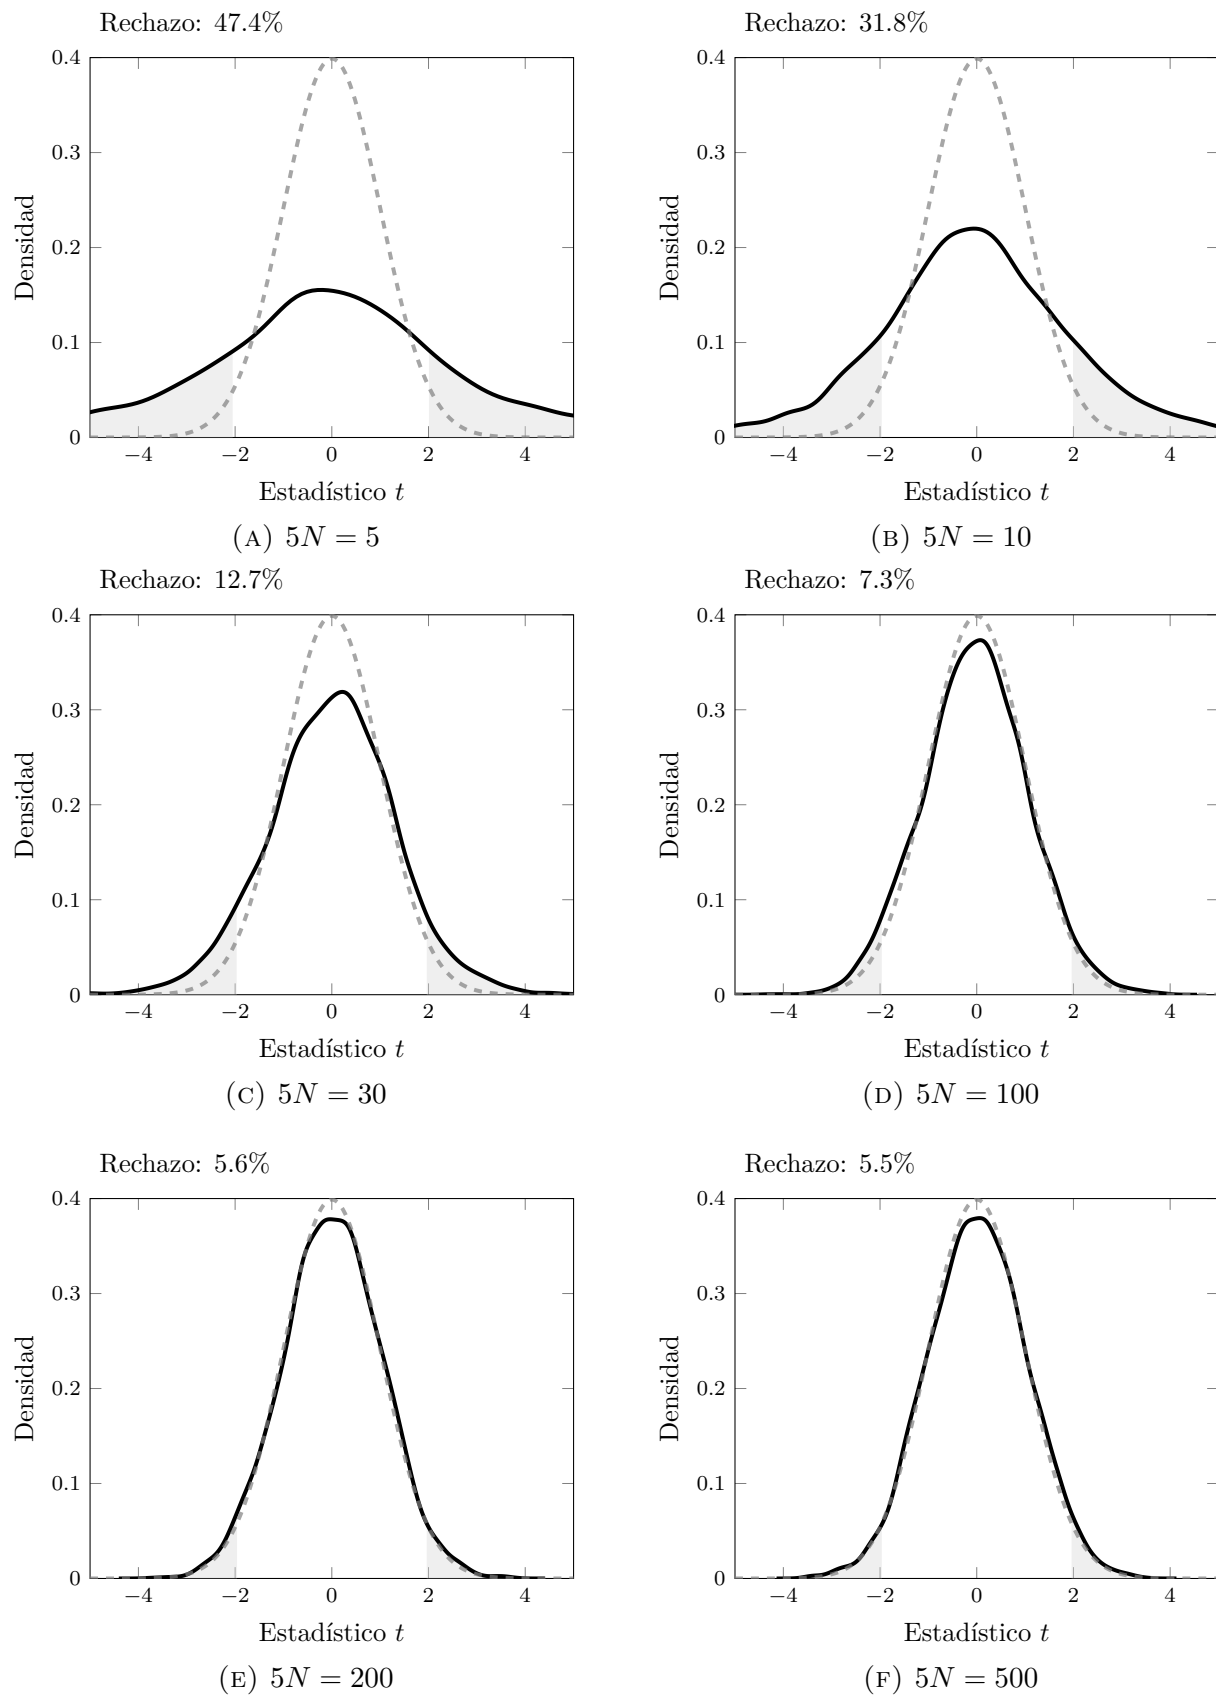
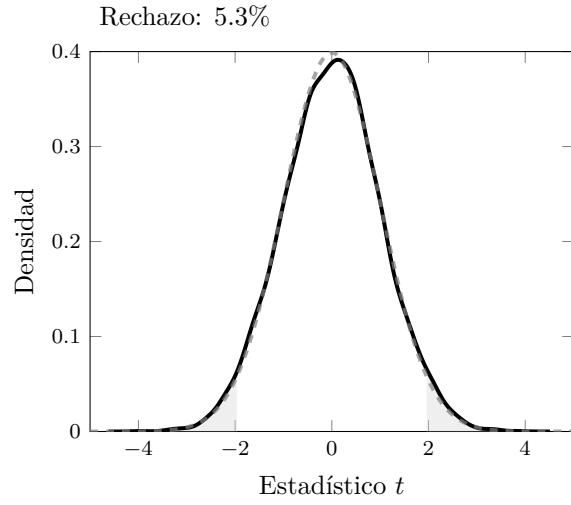


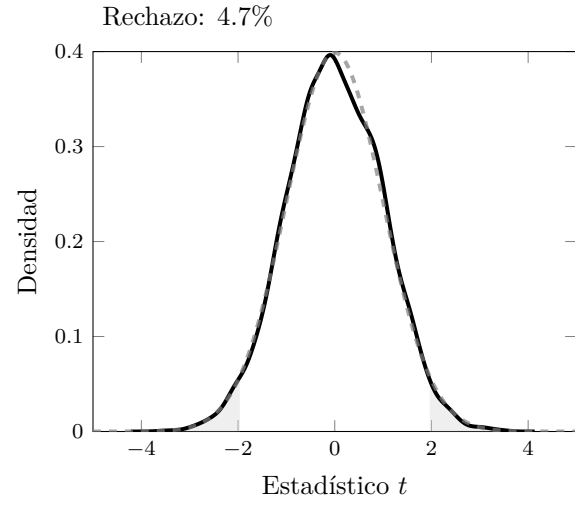
FIGURA 2. Distribución empírica del estadístico t bajo $H_0 : \beta_1 = 0.8$ para FGLS

CUADRO 4. Estadísticos de resumen de estimaciones

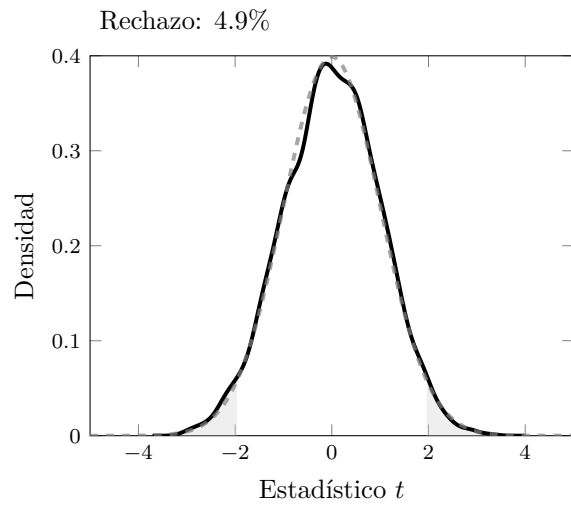
5N	$\beta_1 = 0$				$\beta_1 = 0.4$				$\beta_1 = 0.8$			
	$\tilde{\beta}_{0,\text{fgls}}$		$\tilde{\beta}_{1,\text{fgls}}$		$\tilde{\beta}_{0,\text{fgls}}$		$\tilde{\beta}_{1,\text{fgls}}$		$\tilde{\beta}_{0,\text{fgls}}$		$\tilde{\beta}_{1,\text{fgls}}$	
	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana	Media (desvío)	Mediana
5	-3.0213 (5.3683)	-3.0288	-0.0017 (0.1881)	0.0002	-2.9591 (5.4605)	-2.9627	0.3992 (0.1981)	0.3994	-2.9051 (5.5342)	-2.8620	0.7965 (0.1967)	0.7956
10	-3.0515 (3.0641)	-3.0639	0.0026 (0.1057)	0.0014	-3.0590 (2.9895)	-3.0453	0.4017 (0.1044)	0.4025	-2.9697 (2.9882)	-2.9149	0.7983 (0.1047)	0.7967
30	-2.9800 (1.4150)	-2.9936	-0.0008 (0.0484)	-0.0014	-2.9694 (1.3853)	-2.9472	0.3989 (0.0479)	0.3991	-3.0070 (1.4067)	-3.0254	0.8001 (0.0483)	0.8013
100	-2.9918 (0.6972)	-2.9954	-0.0002 (0.0240)	0.0001	-3.0077 (0.6963)	-3.0044	0.4000 (0.0239)	0.4002	-2.9960 (0.6922)	-3.0048	0.7994 (0.0238)	0.7996
200	-3.0005 (0.4783)	-3.0011	-0.0000 (0.0164)	0.0001	-3.0043 (0.4723)	-3.0155	0.4000 (0.0163)	0.4002	-3.0038 (0.4709)	-3.0060	0.8001 (0.0162)	0.8002
500	-3.0004 (0.3008)	-3.0030	0.0000 (0.0103)	-0.0002	-3.0079 (0.2961)	-3.0062	0.4002 (0.0103)	0.4001	-2.9997 (0.3002)	-3.0019	0.8002 (0.0103)	0.8002



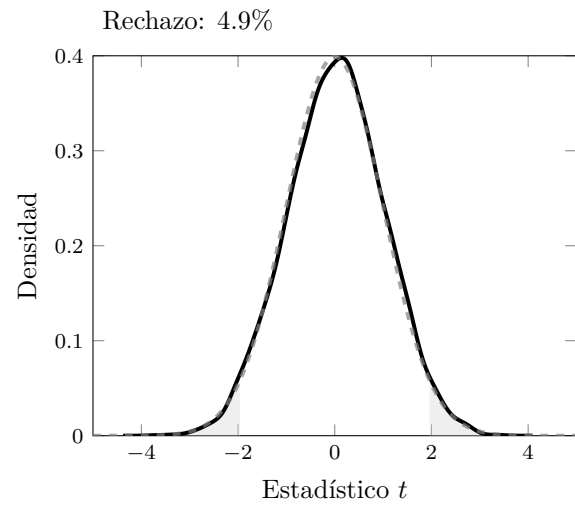
(A) $5N = 5$



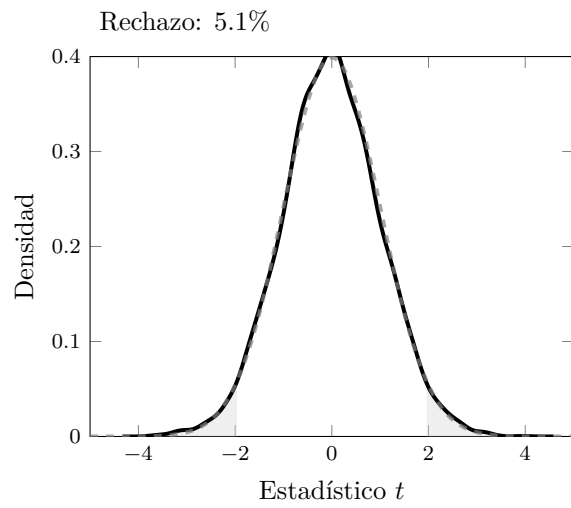
(B) $5N = 10$



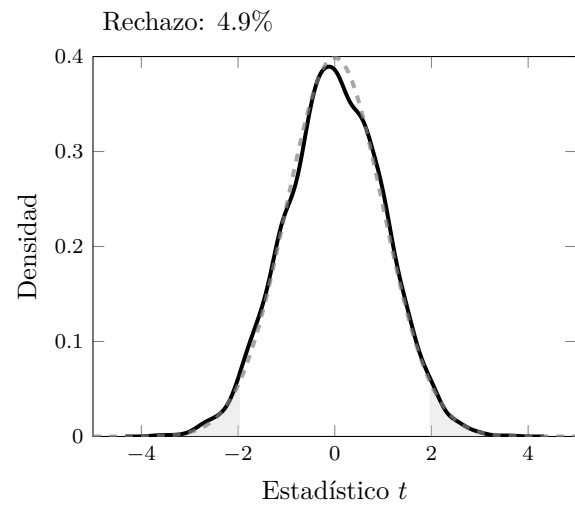
(C) $5N = 30$



(D) $5N = 100$



(E) $5N = 200$



(F) $5N = 500$

FIGURA 3. Distribución empírica del estadístico t bajo $H_0 : \beta_1 = 0.8$ para GLS

2. PROPIEDADES DE MUESTRA FINITA DEL TEST DE WHITE

En este ejercicio se le pide evaluar el funcionamiento del test de heterocedasticidad de White y de la corrección sugerida por este autor para estimar la matriz de varianzas y covarianzas de los coeficientes estimados por mínimos cuadrados clásicos en muestras finitas. El objetivo final del trabajo será aprender bajo qué condiciones es posible aplicar el test de heterocedasticidad y el cálculo correcto de la matriz de varianzas y covarianzas de los coeficientes estimados por mínimos cuadrados clásicos en presencia de heterocedasticidad y confiar en los resultados obtenidos. Para esto considere el modelo

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \sqrt{\nu_i} u_i, \quad i = 1, 2, \dots, n. \quad (6)$$

Para $n = 20$, x_1 se determina como una secuencia de 18 puntos espaciados uniformemente entre -1 y 1 con puntos extremos dados por -1.1 y 1.1 mientras que x_2 son cuantiles de una distribución normal estándar elegidos aleatoriamente. Las observaciones se repiten tres veces para obtener una muestra de $n = 60$, cinco veces para una muestra de $n = 100$, diez veces para una muestra de $n = 200$, veinte veces para una muestra de $n = 400$ y treinta veces para una muestra de $n = 600$. La generación de datos de la variable dependiente se hace con $\beta_0 = \beta_1 = \beta_2 = 1$. Hay tres diseños:

- Diseño 0: $u_i \sim N(0, 1)$ y $\nu_i = 1$ (normalidad y homocedasticidad).
- Diseño 1: $u_i \sim N(0, 1)$ y $\nu_i = e^{0.25x_{1i} + 0.25x_{2i}}$ (normalidad y heterocedasticidad).
- Diseño 2: $u_i \sim t_5$ y $\nu_i = e^{0.25x_{1i} + 0.25x_{2i}}$ (no-normalidad y heterocedasticidad).

Todas las simulaciones se basan en 5 000 replicaciones.

Ejercicio 2 (Test de Heterocedasticidad de White). a) Para el Diseño 0 genere 5 000 muestras de $n = 20$ observaciones a partir del modelo (6). Para cada muestra estime por MCC los parámetros del modelo y realice el test de hipótesis de White para contrastar que H_0 : No hay heterocedasticidad. Reporte tamaño del test al 1 %, 5 % y 10 %.

b) Para los Diseños 1 y 2 genere 5 000 muestras de $n = 20$ observaciones a partir del modelo (6) y reporte el poder del test cuando el diseño utilizado es el modelo poblacional verdadero.

c) Repita el punto anterior con $n = 60$.

d) Repita el punto anterior con $n = 100$.

e) Repita el punto anterior con $n = 200$.

f) Repita el punto anterior con $n = 400$.

g) Repita el punto anterior con $n = 600$.

h) Describa detalladamente las propiedades de muestra finita del test de White de acuerdo a lo observado en los puntos anteriores.

2.1. El modelo. Para $n = 20$, el modelo es¹⁰

$$y_i = \beta_0 + \beta_1 x_{i,1} + \beta_2 x_{i,2} + \sqrt{\nu_i} u_i, \quad i = 1, 2, \dots, 20.$$

¹⁰Nótese que revertimos el orden de los subíndices respecto a la consigna.

donde $x_{i,1}$ es determinístico, siendo una sucesión de veinte puntos equiespaciados entre -1.1 y 1.1 , y $x_{i,2} \stackrel{\text{iid}}{\sim} N(0, 1)$.¹¹ Escribimos el modelo en forma matricial como

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{e}, \quad (7)$$

donde $\mathbf{Y} = (y_1, y_2, \dots, y_{20})'$ es el vector de observaciones de la variable dependiente, $\mathbf{X}$ es la matriz de regresores

$$\mathbf{X} = \begin{bmatrix} 1 & x_{1,1} & x_{1,2} \\ 1 & x_{2,1} & x_{2,2} \\ \vdots & \vdots & \vdots \\ 1 & x_{20,1} & x_{20,2} \end{bmatrix} = \begin{bmatrix} 1 & -1.1 & x_{1,2} \\ 1 & -1 & x_{2,2} \\ \vdots & \vdots & \vdots \\ 1 & 1.1 & x_{20,2} \end{bmatrix},$$

el vector de parámetros es $\beta = (\beta_0, \beta_1, \beta_2)'$ y el vector de errores es $\mathbf{e} = (e_1, e_2, \dots, e_{20})'$, con $e_i = \sqrt{\nu_i}u_i$. Para $n = 20m > 20$, la muestra se obtiene como m realizaciones del modelo (7) concatenadas verticalmente (*stacked*). Por ejemplo, para $n = 40$,

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{20} \\ y_{21} \\ y_{22} \\ \vdots \\ y_{40} \end{bmatrix} = \begin{bmatrix} 1 & -1.1 & x_{1,2} \\ 1 & -1 & x_{2,2} \\ \vdots & \vdots & \vdots \\ 1 & 1.1 & x_{20,2} \\ 1 & -1.1 & x_{21,2} \\ 1 & -1 & x_{22,2} \\ \vdots & \vdots & \vdots \\ 1 & 1.1 & x_{40,2} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_{20} \\ e_{21} \\ e_{22} \\ \vdots \\ e_{40} \end{bmatrix},$$

con $x_{i,2} \stackrel{\text{iid}}{\sim} N(0, 1)$ para $i = 1, 2, \dots, 40$.

2.2. Test de White. El test de White (1980, pág. 825) es un test de la clase de los tests de multiplicadores de Lagrange (*LM* o *score*), que contrasta la hipótesis nula de homocedasticidad. Usando como referencia la descripción de González-Rozada (2025, pág. 67), definimos la *forma funcional de White* como la proyección lineal de la varianza del error $\sqrt{\nu_i}u_i$ en la expansión de segundo orden de los regresores, i.e.,

$$\sigma_i^2 = \gamma_0 + \gamma_1 x_{1i} + \gamma_2 x_{2i} + \gamma_3 x_{1i}^2 + \gamma_4 x_{2i}^2 + \gamma_5 x_{1i} x_{2i} + \varepsilon_i, \quad (8)$$

donde $\sigma_i^2 = \text{var}[\sqrt{\nu_i}u_i \mid x_{1i}, x_{2i}]$ es la varianza condicional del error y ε_i es un error de proyección lineal. La hipótesis nula de homocedasticidad se puede escribir para este modelo como

$$H_0 : \gamma_1 = \gamma_2 = \gamma_3 = \gamma_4 = \gamma_5 = 0, \quad (9)$$

con la alternativa de heterocedasticidad dada por la negación de esta hipótesis nula: al menos alguno de los parámetros $\gamma_1, \gamma_2, \gamma_3, \gamma_4$ o γ_5 es distinto de cero. Puesto que el lado izquierdo

¹¹Siendo precisos, la distancia entre los dos puntos terminales y los adyacentes (0.1) es menor a la distancia entre los puntos intermedios ($1/9 \approx 0.11$), pero es irrelevante. Respecto a x_2 , interpreto que la consigna se refiere con “cuantiles de una distribución normal estándar elegidos aleatoriamente” a $x_2 = \Phi^{-1}(u)$, donde $u \stackrel{\text{iid}}{\sim} U(0, 1)$ y Φ es la función de distribución acumulada de una normal estándar, lo cual es equivalente a $x_2 \stackrel{\text{iid}}{\sim} N(0, 1)$. Hay una ambigüedad en la consigna respecto a la generación de muestras de tamaño mayor a $20m > 20$: ¿debería generarse una sola muestra de $n = 20$, luego copiarla el número de veces necesario para alcanzar el tamaño deseado, o generarse m muestras aleatorias de $n = 20$? Optamos por la segunda opción, aunque los resultados son robustos a la especificación.

de (8) no es observable, el test de White se basa en la estimación de esta ecuación usando como variable dependiente los residuos al cuadrado de la estimación por MCC del modelo (6). Denotando por $\hat{e}_i$ al residuo de OLS de la ecuación (6) para la observación i , definimos la *regresión auxiliar*

$$\hat{e}_i^2 = \gamma_0 + \gamma_1 x_{1i} + \gamma_2 x_{2i} + \gamma_3 x_{1i}^2 + \gamma_4 x_{2i}^2 + \gamma_5 x_{1i} x_{2i} + \varepsilon_i. \quad (10)$$

Estimando por OLS la regresión auxiliar (10) y denotando por R^2 el coeficiente de determinación de esta regresión, el estadístico de test de White es

$$LM := nR^2,$$

que bajo la hipótesis nula de homocedasticidad se distribuye asintóticamente como una chi-cuadrado con 5 grados de libertad (correspondientes a la cantidad de parámetros iguales a cero en la hipótesis nula (9)):

$$LM \xrightarrow{d} \chi_5^2 \quad \text{bajo } H_0.$$

Por lo tanto, nos referimos con *test de nivel o tamaño* α al test a una cola que tiene nivel asintótico α ; más precisamente, región de rechazo

$$R_\alpha = \{LM > \chi_{5,1-\alpha}^2\},$$

donde $\chi_{5,1-\alpha}^2$ es el cuantil $1 - \alpha$ de una variable chi-cuadrado con 5 grados de libertad.¹²

2.3. Monte Carlo con el test de White. Para analizar las propiedades de muestra finita del test de White, realizamos un experimento de Monte Carlo, generando $B = 5000$ muestras de cada diseño y tamaño de muestra, estimando por OLS el modelo (6) para cada muestra, obteniendo los residuos al cuadrado, estimando por OLS la regresión auxiliar (10) para cada muestra, calculando el estadístico de test de White para cada muestra, y finalmente calculando la tasa de rechazo empírica para cada diseño, tamaño de muestra y nivel de significancia asintótico del test.

2.4. Implementaciones. El código para la resolución de este ejercicio se encuentra en el script `scripts/ej2.jl`. A seguir, una breve descripción de las funciones principales usadas.

- `draw_sample` genera una muestra del modelo (7) para un diseño y tamaño de muestra dados. La versión `draw_sample!` muta un *array* pre-asignado para ser más eficiente.
- `ols_fit_k3` es una implementación de OLS optimizada para el caso de $k = 3$ regresores, que es la regresión (6) en este caso. Usa acumulación escalar y *stack-allocated arrays* para ser más eficiente. Resuelve via Cholesky, a diferencia del `ols_2reg` de `scripts/ej1.jl`, que podía aprovechar expresiones escalares del caso simple.
- `ols_fig_k6` es una implementación de OLS optimizada para el caso de $k = 6$ regresores, que es la regresión auxiliar (10) en este caso. También utiliza acumulación escalar y *stack-allocated arrays* para ser más eficiente, y resuelve via Cholesky.
- `white_test` toma una muestra y un nivel de significancia y realiza el test descrito en la sección 2.2. La versión `white_test!` muta *buffers* pre-asignados para ser más eficiente.
- `run_exper` realiza el experimento de Monte Carlo para un diseño y tamaño de muestra dados, generando B muestras.

¹²Es decir, $\chi_{5,1-\alpha}^2$ es el valor tal que $\mathbb{P}[\chi_5^2 \leq \chi_{5,1-\alpha}^2] = 1 - \alpha$. Para $\alpha = 0.01, 0.05$ y 0.10 , usamos valores críticos de 15.09, 11.07 y 9.24, respectivamente.

CUADRO 5. Tasas de rechazo empíricas

n	Diseño 0			Diseño 1			Diseño 2		
	1 %	5 %	10 %	1 %	5 %	10 %	1 %	5 %	10 %
20	0.28 %	4.04 %	8.94 %	0.7 %	6.06 %	12.16 %	0.66 %	5.7 %	11.44 %
60	1.34	5.24	9.76	5.08	15.42	23.56	4.86	12.02	18.3
100	1.46	4.9	8.82	10.84	24.72	36.32	7.52	15.68	23.4
200	1.36	5.22	9.82	30.56	53.5	66.32	12.66	25.82	36.22
400	1.2	5.12	9.66	73.12	89.3	94.5	27.8	47.48	58.42
600	1.18	4.82	9.8	92.86	98.28	99.18	43.04	63.94	74.36

- `run_monte_carlo` realiza el experimento de Monte Carlo para todos los diseños y tamaños de muestra, generando B muestras para cada combinación, y generando gráficos y formando tablas para exportación.

Hay otras funciones relacionadas con la creación y tablas que no son mencionadas en esta sección.

2.5. Resultados del test de White. El cuadro 5 muestra las tasas de rechazo empíricas (i.e., promediadas sobre las 5000 iteraciones del experimento) para el test de White para cada tamaño de muestra y para cada diseño, expresadas como porcentajes del total. Los nombres de las columnas, 1 %, 5 % y 10 %, corresponden al nivel de significancia asintótico del test, como fue descrito en la sección 2.2. Para el Diseño 0, que corresponde a la hipótesis nula de homocedasticidad, las tasas de rechazo empíricas comienzan relativamente cerca del valor asintótico correspondiente, y se acercan a medida que n aumenta, aunque no de manera monótona.¹³ La figura ?? muestra que la distribución empírica del estadístico de test se acerca a la distribución asintótica chi-cuadrado con 5 grados de libertad a medida que aumenta el tamaño de muestra, y también que no se encuentra demasiado alejada de la distribución asintótica incluso para n chico (al menos comparándose con la relación entre el estadístico T del primer ejercicio y su distribución asintótica en la figura 2).

Para los Diseños 1 y 2, que corresponden a la hipótesis alternativa de heterocedasticidad, las tasas de rechazo empíricas comienzan relativamente bajas, tan cercanas al nivel correspondiente al Diseño 0 que es difícil distinguirlas, y aumentan a medida que n aumenta, de manera monótona. Además, como las figuras 5–7 exhiben visualmente, la tasa de rechazo del Diseño 2 se encuentra entre la del Diseño 0 y la del Diseño 1.¹⁴ Esto sugiere que la heterocedasticidad podría ser más difícil de detectar mediante el test de White cuando hay “colas pesadas” en la distribución del error (véase la figura 4). En contraste con el ejercicio anterior, el problema asociado con el tamaño pequeño de la muestra no es el de tamaño grande (i.e., tasas de rechazo empíricas mayores a los niveles correspondientes al Diseño 0), sino el de poder pequeño (i.e., tasas de rechazo empíricas bajas para los Diseños 1 y 2—dificultad para detectar heterocedasticidad). Para valores de n chicos, como por ejemplo $n = 20$, la

¹³Esto se debe, uno presume, a la aleatoriedad de las simulaciones de Monte Carlo, pero aún con un millón de replicaciones en lugar de cinco mil, la convergencia no es monótona.

¹⁴Cada figura muestra la tasa de rechazo empírica para cada valor crítico (correspondiente a un nivel de significancia asintótico) para cada tamaño de muestra, con una línea para cada diseño. Las simulaciones se realizaron con $B = 100\,000$ simulaciones en lugar de $B = 5\,000$ para eliminar mejor la aleatoriedad del experimento.

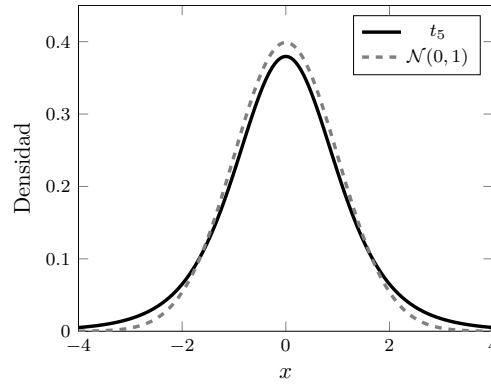
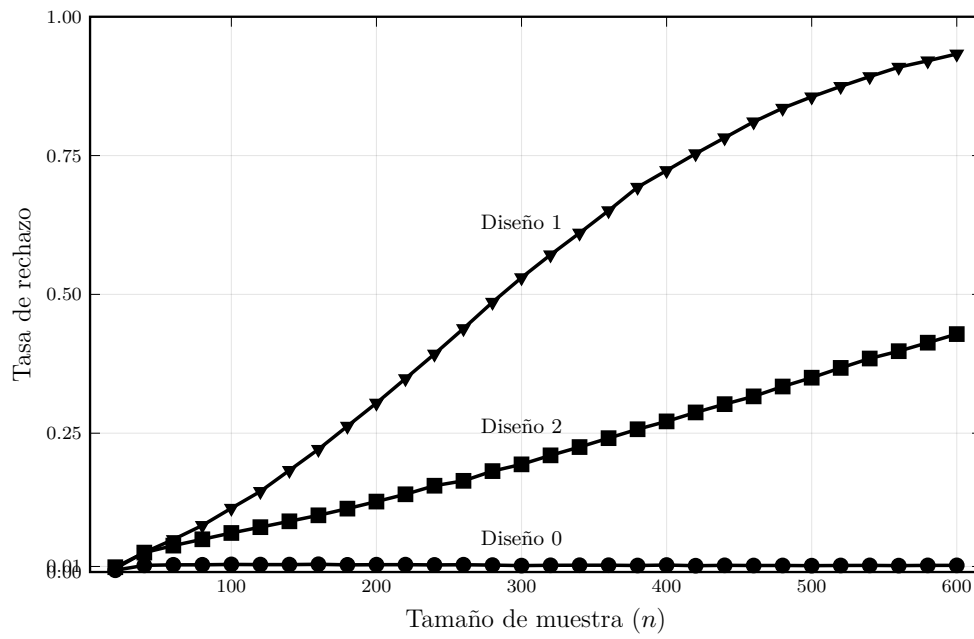
FIGURA 4. Distribución normal estándar y t_5 de Student

FIGURA 5. Tasas de rechazo empíricas al 1 %

probabilidad de rechazar correctamente homocedasticidad es solo un poco mayor que la probabilidad de rechazar incorrectamente homocedasticidad. A medida que aumenta n , este problema de poder pequeño se resuelve, aunque más rápido para el Diseño 1 que para el Diseño 2.

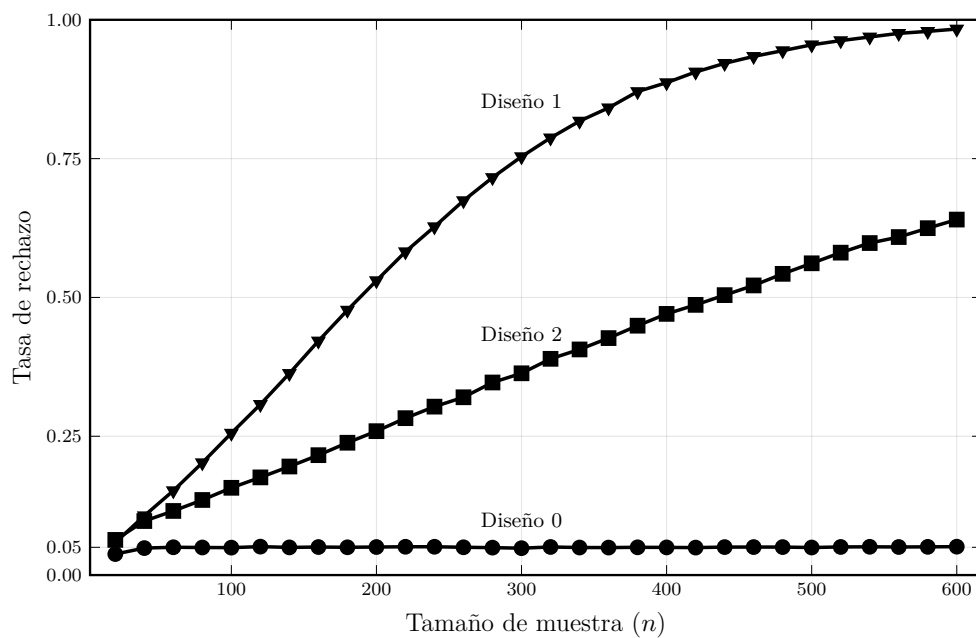


FIGURA 6. Tasas de rechazo empíricas al 5 %

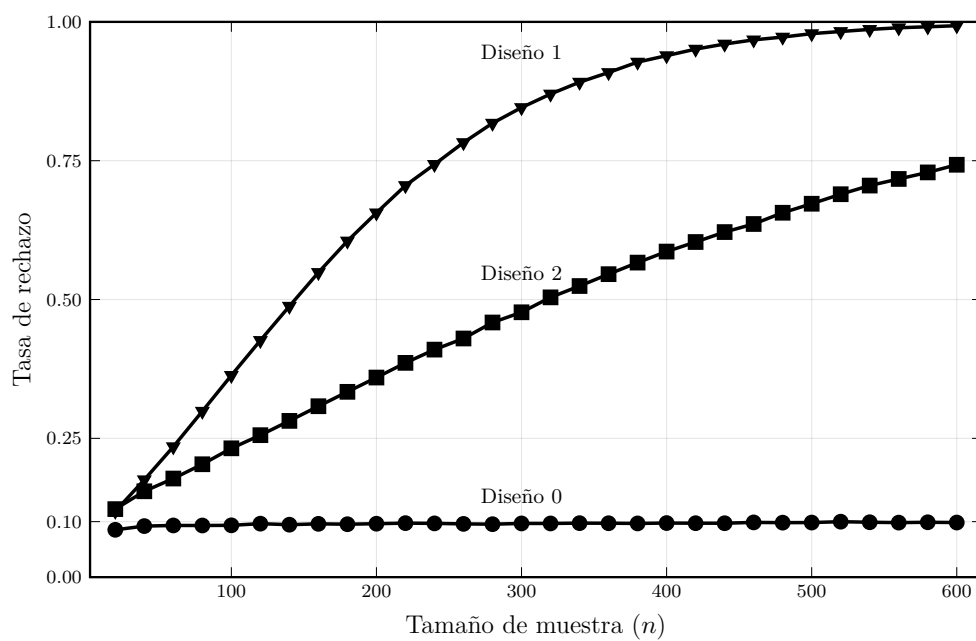


FIGURA 7. Tasas de rechazo empíricas al 10 %

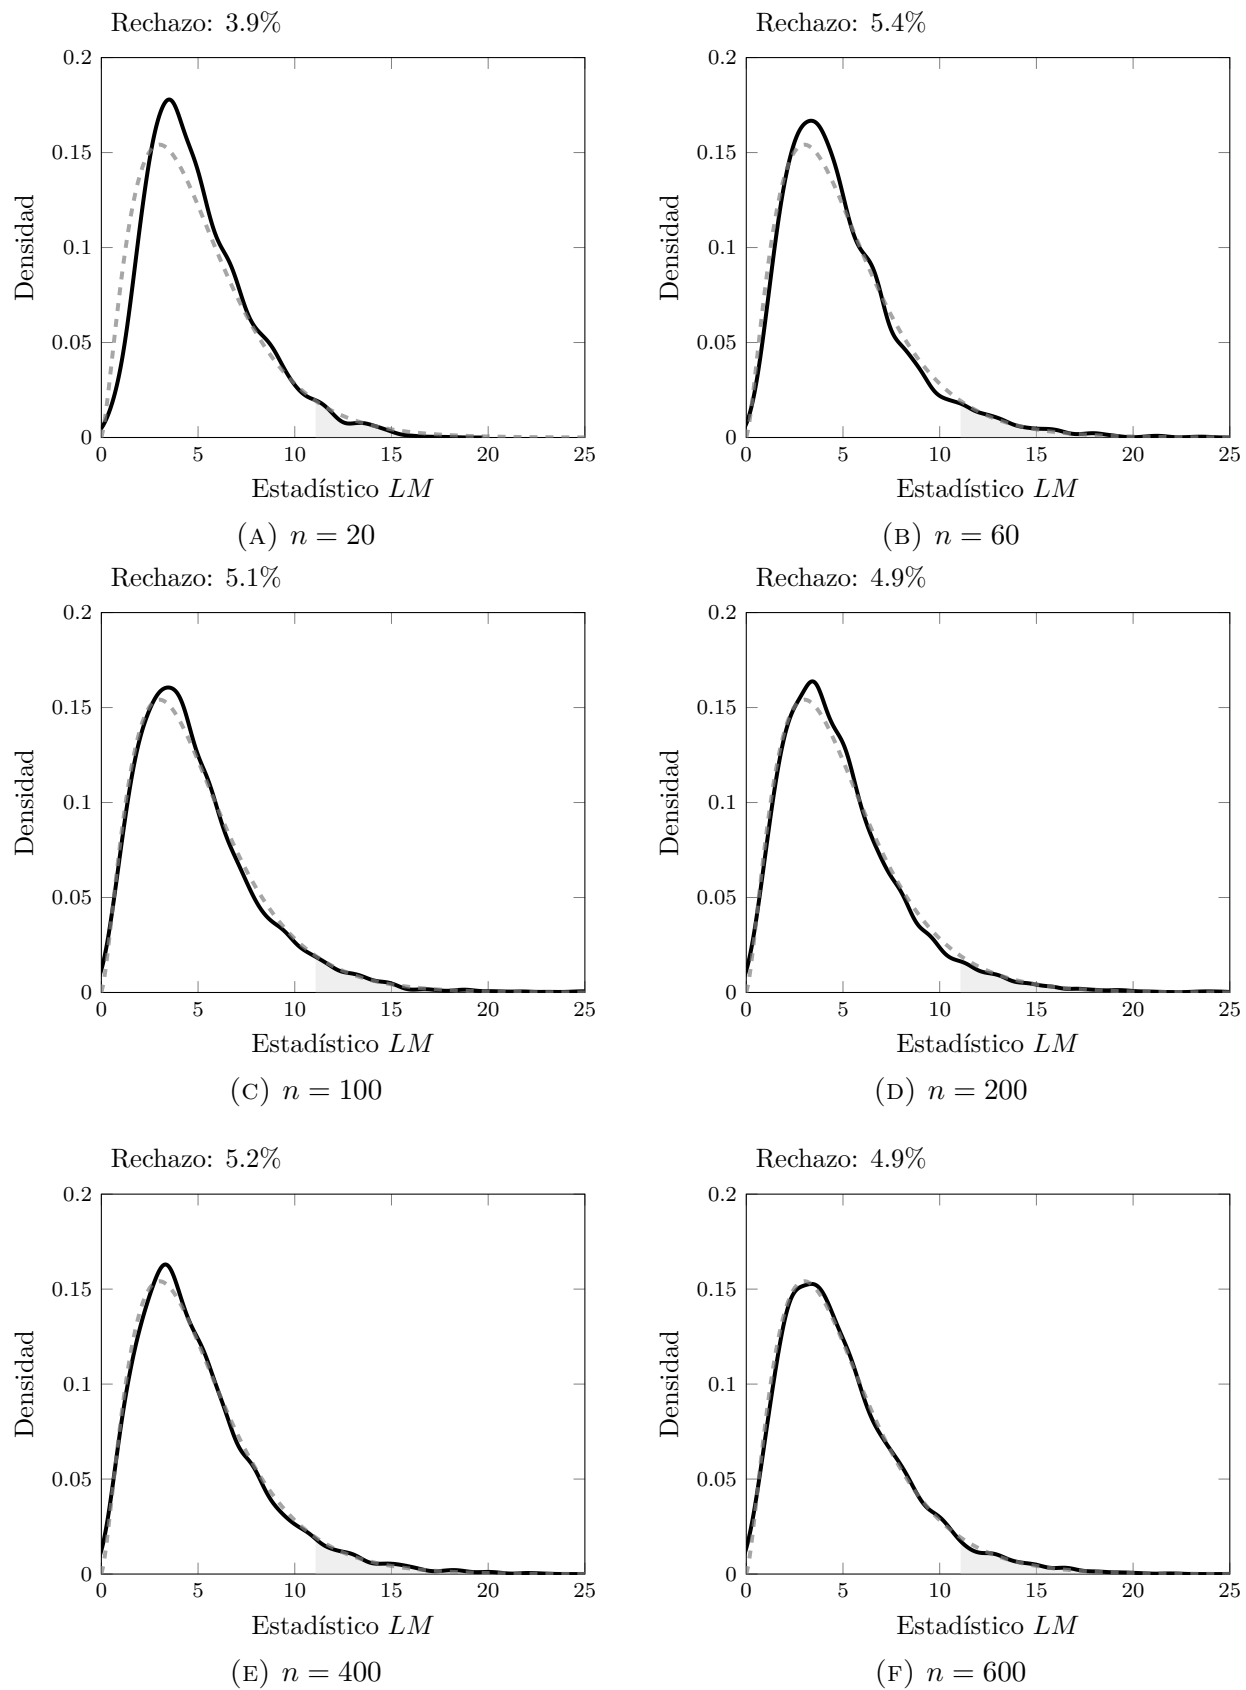


FIGURA 8. Distribución empírica del estadístico LM bajo Diseño 0

Ejercicio 3 (Corrección de la matriz de varianzas y covarianzas en presencia de heterocedasticidad). En el modelo de regresión lineal (6) la estimación de MCC es

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = (X'X)^{-1}X'y,$$

donde X es la matriz de variables explicativas de dimensión $n \times 3$ e y es el vector de observaciones de la variable dependiente de dimensión $n \times 1$. Bajo heterocedasticidad, la matriz de varianzas y covarianzas de los estimadores de MCC es

$$\text{var}[\hat{\beta}] = (X'X)^{-1}X'\Omega X(X'X)^{-1}, \quad (11)$$

con $\Omega = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$. Una estimación consistente de esta matriz está dada por la denominada matriz de White (1980),

$$\widehat{\text{var}}[\hat{\beta}] = (X'X)^{-1}X'\hat{\Omega}X(X'X)^{-1},$$

con $\hat{\Omega} = \text{diag}(\hat{u}_1^2, \dots, \hat{u}_n^2)$ y $\hat{u}$ el vector de dimensión $n \times 1$ de residuos de la estimación por MCC.

- Para cada uno de los Diseños 1 y 2 genere 5 000 muestras de $n = 20$ observaciones a partir del modelo (6). Para cada muestra estime por MCC los parámetros del modelo y reporte el sesgo relativo de la estimación de las varianzas de $\hat{\beta}_0$, $\hat{\beta}_1$ y $\hat{\beta}_2$ y los sesgos relativos totales. El sesgo relativo (b_0, b_1, b_2) se define como el promedio, a lo largo de las 5 000 simulaciones, de la varianza estimada menos la varianza verdadera dividido por la varianza verdadera, y el sesgo relativo total es la suma del valor absoluto de b_0 , b_1 y b_2 . El sesgo relativo total es una medida del sesgo agregado de las tres variables.
- Repita el punto anterior con $n = 60$.
- Repita el punto anterior con $n = 100$.
- Repita el punto anterior con $n = 200$.
- Repita el punto anterior con $n = 400$.
- Repita el punto anterior con $n = 600$.
- Repita los puntos a) a f) pero ahora construya la estimación de la matriz de White usando una matriz diagonal con los errores verdaderos elevados al cuadrado en lugar de utilizar la matriz diagonal con los residuos elevados al cuadrado.
- Describa detalladamente las propiedades de muestra finita de la estimación de las varianzas de los coeficientes de MCC robustas ante la presencia de heterocedasticidad (con el procedimiento de White) de acuerdo a lo observado en los puntos anteriores.

2.6. Estimadores de matriz de varianzas y covarianzas. La siguiente discusión de estimadores alternativos de la matriz de varianzas y covarianzas de los coeficientes estimados por OLS en presencia de heterocedasticidad es esencialmente la de Hansen (2022, págs. 114-116).

Como dice la ecuación (11), la matriz de varianzas y covarianzas del estimador OLS $\hat{\beta}$ se puede escribir

$$V_{\hat{\beta}} := \text{var}[\hat{\beta} | \mathbf{X}] = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{D}\mathbf{X})(\mathbf{X}'\mathbf{X})^{-1}, \quad (12)$$

donde

$$\mathbf{D} := \Omega = \text{diag}(\sigma_1^2, \dots, \sigma_n^2) = E[\mathbf{e}\mathbf{e}' \mid \mathbf{X}].$$

Si pudiésemos observar los errores, podríamos estimar D de manera insesgada con $\mathbf{e}\mathbf{e}'$, y construir el estimador

$$\widehat{\mathbf{V}}_{\widehat{\beta}}^{\text{ideal}} = (\mathbf{X}'\mathbf{X})^{-1} \left(\sum_{i=1}^n X_i X_i' e_i^2 \right) (\mathbf{X}'\mathbf{X})^{-1}. \quad (13)$$

El estimador de la ecuación (13) es el que propone el inciso g). No es un estimador, estrictamente hablando, porque no es función de la muestra, pero como estimador *infeasible* sirve como una referencia contra la cual comparar el desempeño de los estimadores factibles.

Desarrollada en su primera instancia por Eicker (1963) e introducida a la econometría por White (1980), la denominada *matriz de White* (o de Eicker-White) se define

$$\widehat{\mathbf{V}}_{\widehat{\beta}}^{\text{HC0}} = (\mathbf{X}'\mathbf{X})^{-1} \left(\sum_{i=1}^n X_i X_i' \widehat{e}_i^2 \right) (\mathbf{X}'\mathbf{X})^{-1}. \quad (14)$$

El “HC0” en el supraíndice se refiere a que es el estimador *baseline* en la clase *heteroskedasticity-consistent*. En la práctica, como en la implementación de la opción `robust` de Stata, se suele hacer una corrección *ad-hoc* propuesta por Hinkley (1977),

$$\widehat{\mathbf{V}}_{\widehat{\beta}}^{\text{HC1}} = \frac{n}{n-k} (\mathbf{X}'\mathbf{X})^{-1} \left(\sum_{i=1}^n X_i X_i' \widehat{e}_i^2 \right) (\mathbf{X}'\mathbf{X})^{-1}. \quad (15)$$

Otros estimadores que se utilizan son el “HC2” de Horn et al. (1975) y el “HC3” propuesto por MacKinnon y White (1985) y por Andrews (1991), que utilizan en lugar de los residuos de OLS, residuos estandarizados y errores de predicción, respectivamente.

La consigna hace referencia a “la matriz de White”. En la implementación, usamos las dos versiones: la original (HC0) y la que incluye la corrección de Hinkley (HC1).

2.7. Sesgo relativo. Consideremos el contexto de un experimento Monte Carlo con replicaciones $b = 1, 2, \dots, B$. Sea $\widehat{\mathbf{V}}^{(b)}$ la b -ésima instancia de un estimador de la matriz de varianzas y covarianzas de $\widehat{\beta}$, y $\widehat{\mathbf{V}}_{jj}^{(b)}$ la varianza estimada de $\widehat{\beta}_j$ dada por el elemento j -ésimo de la diagonal de $\widehat{\mathbf{V}}^{(b)}$. De la misma manera, la verdadera varianza condicional de $\widehat{\beta}_j$ dada la b -ésima matriz de datos $\mathbf{X}^{(b)}$ es el elemento j -ésimo de la diagonal de $\mathbf{V}_{\widehat{\beta}}^{(b)}$, que denotamos por $\mathbf{V}_{\widehat{\beta},jj}^{(b)}$.¹⁵ El sesgo relativo de $\widehat{\mathbf{V}}_{jj}$ denotado por b_j se define como el promedio a lo largo de las B simulaciones de la varianza estimada menos la varianza verdadera dividido por la varianza verdadera, es decir,

$$b_j = \frac{1}{B} \sum_{b=1}^B \frac{\widehat{\mathbf{V}}_{jj}^{(b)} - \mathbf{V}_{\widehat{\beta},jj}^{(b)}}{\mathbf{V}_{\widehat{\beta},jj}^{(b)}}.$$

El sesgo relativo total es la suma del valor absoluto de b_0 , b_1 y b_2 :

$$\|\mathbf{b}\|_1 = |b_0| + |b_1| + |b_2|.$$

La notación alude a que el sesgo relativo total es la norma ℓ_1 del vector de sesgos relativos $\mathbf{b} = (b_0, b_1, b_2)'$ en $\mathbb{R}^3$.

¹⁵La varianza condicional varía con la replicación porque varía la matriz de datos $\mathbf{X}^{(b)}$.

2.8. El Experimento. El experimento consiste en generar $B = 5\,000$ muestras de cada diseño y cada tamaño de muestra, estimar por OLS el modelo (6) para cada muestra, y luego, a lo largo de las B muestras, calcular el sesgo relativo de la matriz de White (HC0 y HC1, de las ecuaciones (14) y (15)) y del estimador *infeasible* ideal de la ecuación (13).

2.9. Implementaciones. El código para la resolución de este ejercicio se encuentra en el script `scripts/ej3.jl`. A seguir, una breve descripción de las funciones principales usadas.

- `draw_sample_e` genera una muestra de la misma manera que la función `draw_sample` de `scripts/ej2.jl`, pero también devuelve los errores verdaderos de la muestra, que son necesarios para el inciso g). La razón por la cual no se usa la misma función para ambos es que el error no es necesario para el experimento del inciso anterior y ocupa memoria. La versión `draw_sample_e!` muta un *array* pre-asignado para ser más eficiente.
- `vcov_diags` computa los elementos diagonales de las matrices en las ecuaciones (12), (13), (14) y (15), i.e., computan varianzas de coeficientes o estimaciones de varianzas de coeficientes.
- `run_exper` realiza el experimento de Monte Carlo para un diseño y tamaño de muestra dados, generando B muestras.
- `run_monte_carlo` realiza el experimento de Monte Carlo para todos los diseños y tamaños de muestra, generando B muestras para cada combinación, y generando gráficos y formando tablas para exportación.

Hay otras funciones relacionadas con la creación y tablas que no son mencionadas en esta sección.

2.10. Resultados. El cuadro 6 muestra los sesgos relativos de la matriz de White (HC0) y del estimador *infeasible* ideal, para cada diseño y cada tamaño de muestra. El cuadro 7 compara la matriz de White sin la corrección de Hinkley (HC0) con la que incluye esta corrección (HC1). Las figuras 9 y 10 muestran el sesgo relativo total para cada diseño y cada tamaño de muestra, mientras que las figuras 11a–13b muestran el sesgo relativo de cada componente de la matriz de varianzas y covarianzas.¹⁶ En primer lugar, notemos que HC1 domina a HC0 en términos de sesgo relativo: la estimación de la matriz de varianzas y covarianzas con la corrección de Hinkley tiene menor sesgo en valor absoluto para todo n , para todo diseño, y para cada componente de la matriz de varianzas y covarianzas. Además, el sesgo relativo para la constante, b_0 , es prácticamente idéntico entre HC1 e $V_{\hat{\beta}}^{\text{ideal}}$, y muy cercano a cero, mientras que el sesgo de HC0 es considerable. Todos los sesgos de HC0 son negativos, y la mayoría de los sesgos de HC1, lo cual quiere decir que subestiman la varianza de los coeficientes, aunque el sesgo de HC1 es bastante menor que el de HC0, en particular para las varianzas de $\hat{\beta}_0$ y $\hat{\beta}_1$.

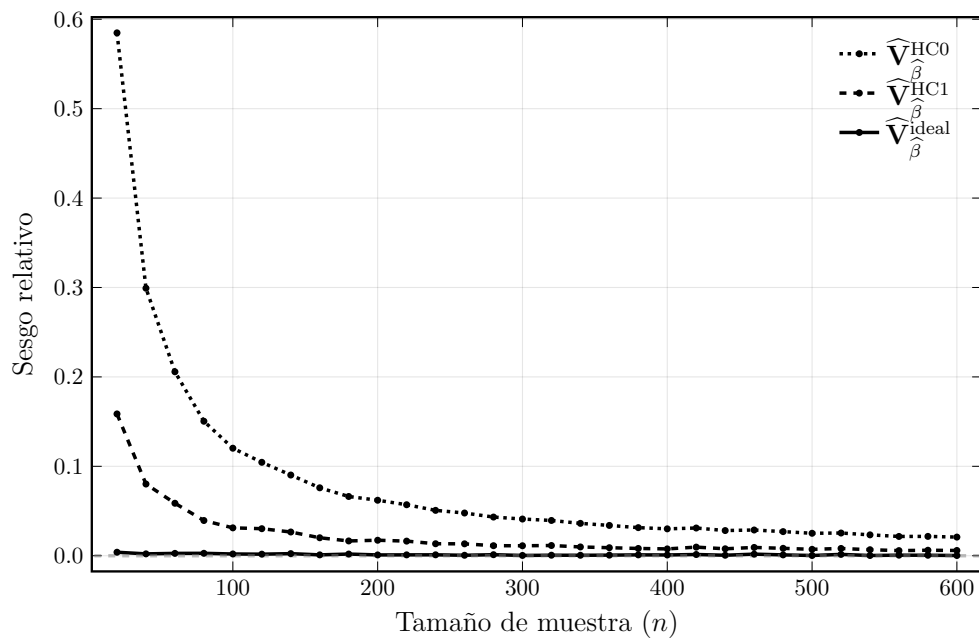
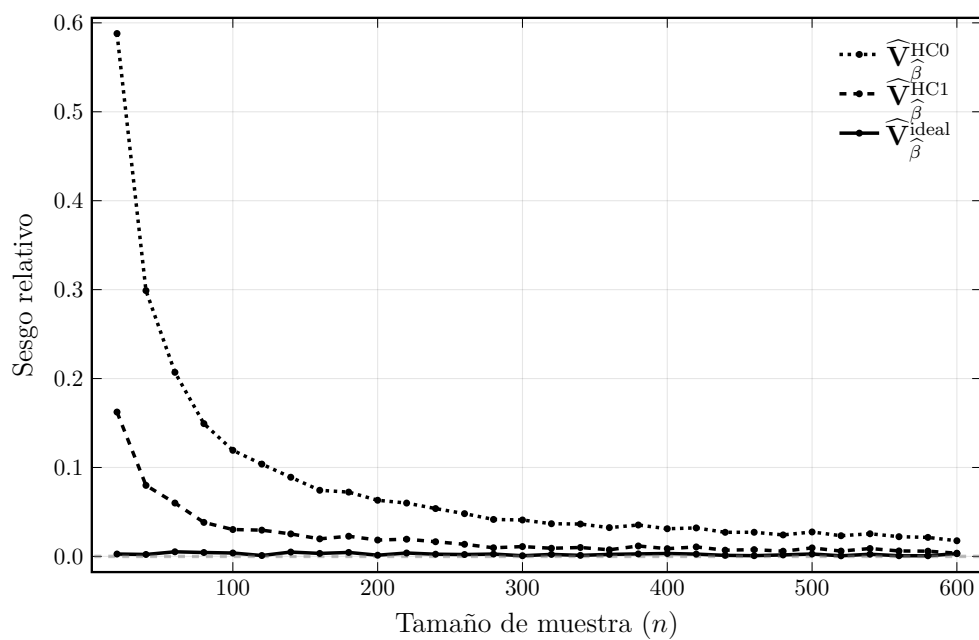
¹⁶Las tablas usan la cantidad de simulaciones que dice la consigna, $B = 5\,000$, mientras que las figuras, para obtener una mejor representación gráfica y eliminar características espurias del experimento, como líneas que se cruzan para algunos n , usan $B = 100\,000$ simulaciones.

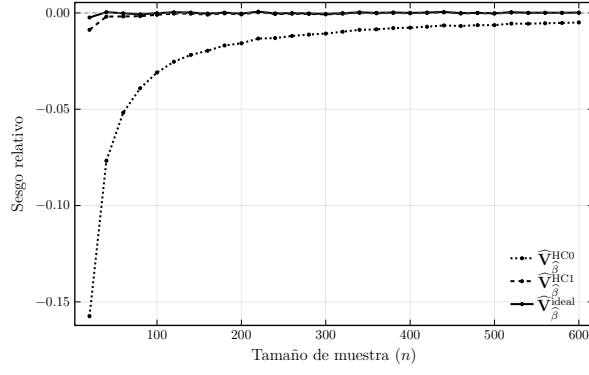
CUADRO 6. Sesgo relativo de HC0 e $V_{\hat{\beta}}^{\text{ideal}}$

n	Diseño 1								Diseño 2							
	$\hat{V}^{\text{HC0}}$				$\hat{V}^{\text{ideal}}$				$\hat{V}^{\text{HC0}}$				$\hat{V}^{\text{ideal}}$			
	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$
20	-0.154	-0.191	-0.233	0.579	0.002	0.003	-0.003	0.008	-0.152	-0.190	-0.227	0.569	0.004	-0.003	0.018	0.025
60	-0.052	-0.067	-0.091	0.209	-0.001	-0.002	-0.006	0.009	-0.051	-0.065	-0.082	0.199	0.001	-0.002	0.006	0.008
100	-0.030	-0.040	-0.051	0.121	0.002	-0.001	0.003	0.005	-0.030	-0.033	-0.049	0.112	0.001	0.006	0.004	0.011
200	-0.015	-0.021	-0.029	0.065	0.000	-0.001	-0.002	0.003	-0.017	-0.017	-0.033	0.067	-0.002	0.002	-0.007	0.011
400	-0.005	-0.007	-0.009	0.021	0.002	0.003	0.005	0.010	-0.007	-0.010	-0.009	0.027	0.001	-0.000	0.004	0.005
600	-0.006	-0.008	-0.009	0.023	-0.001	-0.002	0.000	0.002	-0.003	-0.004	-0.001	0.008	0.002	0.003	0.008	0.013

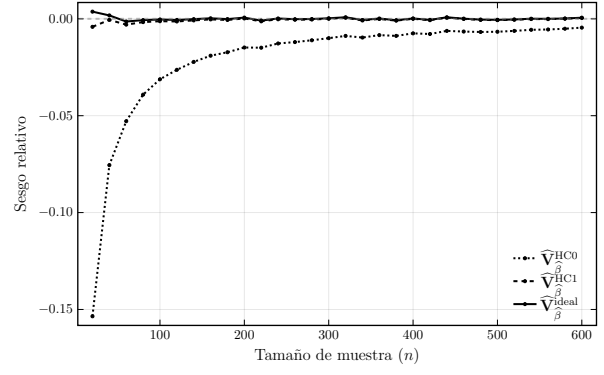
CUADRO 7. Comparación entre HC0 y HC1

n	Diseño 1								Diseño 2							
	$\hat{V}^{\text{HC0}}$				$\hat{V}^{\text{HC1}}$				$\hat{V}^{\text{HC0}}$				$\hat{V}^{\text{HC1}}$			
	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$	b_0	b_1	b_2	$\ \mathbf{b}\ _1$
20	-0.154	-0.191	-0.233	0.579	-0.005	-0.048	-0.098	0.151	-0.152	-0.190	-0.227	0.569	-0.003	-0.047	-0.090	0.140
60	-0.052	-0.067	-0.091	0.209	-0.002	-0.018	-0.043	0.063	-0.051	-0.065	-0.082	0.199	-0.001	-0.016	-0.034	0.051
100	-0.030	-0.040	-0.051	0.121	0.000	-0.011	-0.021	0.032	-0.030	-0.033	-0.049	0.112	-0.000	-0.003	-0.020	0.023
200	-0.015	-0.021	-0.029	0.065	-0.000	-0.006	-0.014	0.020	-0.017	-0.017	-0.033	0.067	-0.002	-0.002	-0.019	0.023
400	-0.005	-0.007	-0.009	0.021	0.002	0.001	-0.001	0.004	-0.007	-0.010	-0.009	0.027	0.000	-0.003	-0.002	0.005
600	-0.006	-0.008	-0.009	0.023	-0.001	-0.003	-0.004	0.008	-0.003	-0.004	-0.001	0.008	0.002	0.001	0.004	0.007

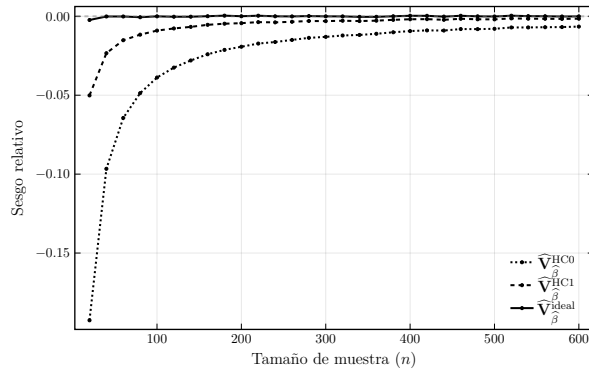
FIGURA 9. Sesgo relativo total $\|\mathbf{b}\|_1$ para el Diseño 1FIGURA 10. Sesgo relativo total $\|\mathbf{b}\|_1$ para el Diseño 2



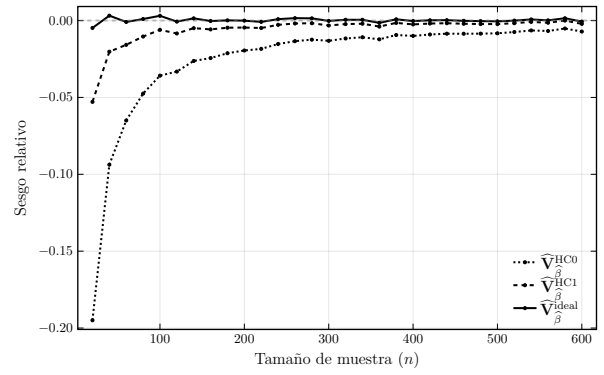
(A) Diseño 1



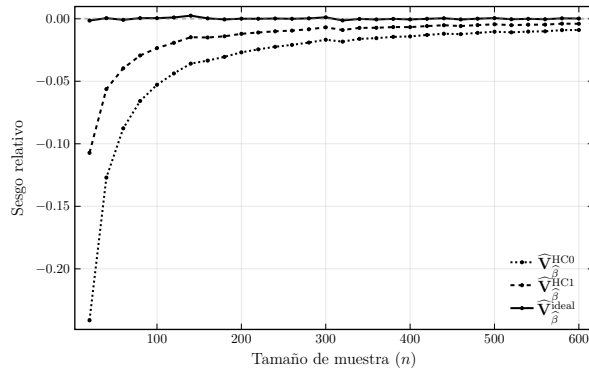
(B) Diseño 2

FIGURA 11. Sesgo relativo b_0 

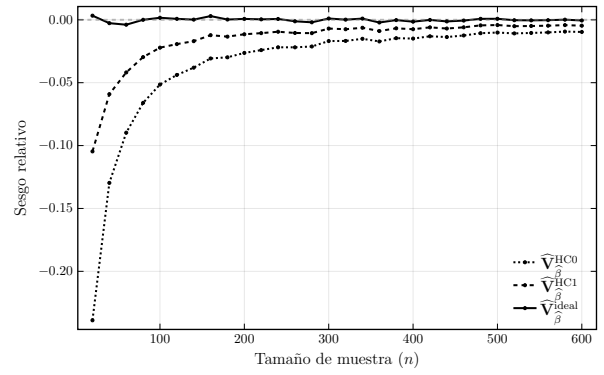
(A) Diseño 1



(B) Diseño 2

FIGURA 12. Sesgo relativo b_1 

(A) Diseño 1



(B) Diseño 2

FIGURA 13. Sesgo relativo b_2

REFERENCIAS

- Aitken, A. C. (1935). "On Least Squares and Linear Combination of Observations". En: *Proceedings of the Royal Society of Edinburgh* 55, págs. 42-48. ISSN: 0370-1646. DOI: 10.1017/S0370164600014346. URL: https://www.cambridge.org/core/product/identifier/S0370164600014346/type/journal_article (visitado 15-02-2025).
- Andrews, Donald W. K. (1991). "Asymptotic Normality of Series Estimators for Nonparametric and Semiparametric Regression Models". En: *Econometrica* 59.2, págs. 307-345. ISSN: 0012-9682. DOI: 10.2307/2938259. JSTOR: 2938259. URL: <https://www.jstor.org/stable/2938259> (visitado 21-02-2026).
- Eicker, F. (jun. de 1963). "Asymptotic Normality and Consistency of the Least Squares Estimators for Families of Linear Regressions". En: *The Annals of Mathematical Statistics* 34.2, págs. 447-456. ISSN: 0003-4851. DOI: 10.1214/aoms/1177704156. URL: <http://projecteuclid.org/euclid.aoms/1177704156> (visitado 20-02-2026).
- González-Rozada, Martín (2025). "Lecture 2". Lecture notes, Econometría, Universidad Torcuato Di Tella (Buenos Aires).
- Hansen, Bruce E. (2022). *Econometrics*. Princeton Oxford: Princeton University Press. 1044 págs. ISBN: 978-0-691-23589-9.
- Hinkley, David V. (1977). "Jackknifing in Unbalanced Situations". En: *Technometrics* 19.3, págs. 285-292. ISSN: 0040-1706. DOI: 10.2307/1267698. JSTOR: 1267698. URL: <https://www.jstor.org/stable/1267698> (visitado 20-02-2026).
- Horn, Susan D., Roger A. Horn y David B. Duncan (1975). "Estimating Heteroscedastic Variances in Linear Models". En: *Journal of the American Statistical Association* 70.350, págs. 380-385. ISSN: 0162-1459. DOI: 10.2307/2285827. JSTOR: 2285827. URL: <https://www.jstor.org/stable/2285827> (visitado 21-02-2026).
- MacKinnon, James G y Halbert White (1 de sep. de 1985). "Some Heteroskedasticity-Consistent Covariance Matrix Estimators with Improved Finite Sample Properties". En: *Journal of Econometrics* 29.3, págs. 305-325. ISSN: 0304-4076. DOI: 10.1016/0304-4076(85)90158-7. URL: <https://www.sciencedirect.com/science/article/pii/0304407685901587> (visitado 21-02-2026).
- White, Halbert (1980). "A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity". En: *Econometrica* 48.4, págs. 817-838. ISSN: 0012-9682. DOI: 10.2307/1912934. JSTOR: 1912934. URL: <https://www.jstor.org/stable/1912934> (visitado 16-02-2025).

APÉNDICE A. CÓDIGO

A.1. Ejercicio 1. El contenido del archivo ej1.jl es el siguiente

```

1 # =====
2 # TRABAJO FINAL ECONOMETRIA
3 # Ejercicio 1: Propiedades de muestra finita de FGLS
4 #
5 # Autor: Felipe Tappata
6 # Fecha: Febrero 2026
7 # =====
8
9 # Load dependencies
10 using Random, Plots, Statistics
11 using LinearAlgebra
12 using Printf, LaTeXStrings
13 using KernelDensity
14 using Distributions
15 using PGFPlotsX
16
17 # Set seed
18 const SEED = 8869
19 Random.seed!(SEED)
20
21 # Set plotting backend
22 pgfplotsx()
23 default(tex_output_standalone=false)
24
25
26 # === ESTIMATION FUNCTIONS ===
27
28 """
29     draw_sample(N; rng=Random.default_rng(),
30                 beta0=-3.0,
31                 beta1=0.8,
32                 omega=(4.0, 9.0, 16.0, 25.0, 36.0))
33
34     Generate one sample of length '5N' from the heteroskedastic linear model
35     'y = beta0 + beta1*x + u', with 'x ~ Uniform(1,50)' and 'Var(u) =  $\Omega \otimes I_N$ '.
36
37 # Arguments
38 - 'N::Integer': number of replications per type (total sample size is '5N').
39
40 # Keyword arguments
41 - 'rng::AbstractRNG': random number generator (default: 'Random.default_rng()').
42 - 'beta0::Real': intercept.
43 - 'beta1::Real': slope.

```

```

44 - 'omega::NTuple{5,<:Real}': variances ' $(\omega_1, \dots, \omega_5)$ ' for the five types.
45
46 # Returns
47 - 'x::Vector{Float64}': regressor values, length '5N'.
48 - 'y::Vector{Float64}': dependent variable values, length '5N'.
49 - 'k::Vector{Int}': type index in ' $\{1, \dots, 5\}$ ' for each observation.
50
51 The stacking order is consistent with ' $\Sigma = \Omega \otimes I_N$ ':
52 all observations of type 'k' are contiguous.
53 """
54 function draw_sample(
55     N::Integer;
56     rng::AbstractRNG = Random.default_rng(),
57     beta0::Real = -3.0,
58     beta1::Real = 0.8,
59     omega::NTuple{5,<:Real} = (4.0, 9.0, 16.0, 25.0, 36.0),
60 )
61     N = Int(N)
62     n = 5N
63     x = Vector{Float64}(undef, n)
64     y = Vector{Float64}(undef, n)
65     k = Vector{Int}(undef, n)
66
67     idx = 0
68     @inbounds for type in 1:5
69          $\sigma$  = sqrt(Float64(omega[type]))
70         for _ in 1:N
71             idx += 1
72             xi = 1.0 + 49.0 * rand(rng)           #  $U(1, 50)$ 
73             ui =  $\sigma$  * randn(rng)              #  $N(0, \omega_{\text{type}})$ 
74             x[idx] = xi
75             y[idx] = Float64(beta0) + Float64(beta1)*xi + ui
76             k[idx] = type
77         end
78     end
79
80     return x, y, k
81 end
82
83 """
84 draw_sample!(x, y, k, N; rng=Random.default_rng(),
85             beta0=-3.0,
86             beta1=0.8,
87             omega=(4.0, 9.0, 16.0, 25.0, 36.0))
88
89 In-place version of 'draw_sample'. Mutates pre-allocated arrays 'x', 'y', 'k'.
90 More memory-efficient for Monte Carlo simulations with repeated sampling.

```

```

91
92 # Arguments
93 - 'x::AbstractVector{Float64}': pre-allocated regressor array, length '5N'.
94 - 'y::AbstractVector{Float64}': pre-allocated dependent variable array, length
  ↪ '5N'.
95 - 'k::AbstractVector{Int}': pre-allocated type index array, length '5N'.
96 - 'N::Integer': number of replications per type.
97
98 # Keyword arguments
99 - 'rng::AbstractRNG': random number generator (default: 'Random.default_rng()').
100 - 'beta0::Real': intercept.
101 - 'beta1::Real': slope.
102 - 'omega::NTuple{5,<:Real}': variances ' $(\omega_1, \dots, \omega_5)$ ' for the five types.
103 """
104 function draw_sample!(
105     x::AbstractVector{Float64},
106     y::AbstractVector{Float64},
107     k::AbstractVector{Int},
108     N::Integer;
109     rng::AbstractRNG = Random.default_rng(),
110     beta0::Real = -3.0,
111     beta1::Real = 0.8,
112     omega::NTuple{5,<:Real} = (4.0, 9.0, 16.0, 25.0, 36.0),
113 )
114     N = Int(N)
115     n = 5N
116     @assert length(x) == n && length(y) == n && length(k) == n
117
118     idx = 0
119     @inbounds for type in 1:5
120          $\sigma$  = sqrt(Float64(omega[type]))
121         for _ in 1:N
122             idx += 1
123             xi = 1.0 + 49.0 * rand(rng)           # U(1,50)
124             ui =  $\sigma$  * randn(rng)              # N(0,  $\omega_{type}$ )
125             x[idx] = xi
126             y[idx] = Float64(beta0) + Float64(beta1)*xi + ui
127             k[idx] = type
128         end
129     end
130
131     return nothing
132 end
133
134 """
135     ols_2reg(x, y)
136

```

```

137 OLS for  $y = b_0 + b_1x$  with scalar sums. Returns  $(b_0, b_1)$ .
138 """
139 function ols_2reg(x::AbstractVector{<:Real}, y::AbstractVector{<:Real})
140     n = length(x)
141     @assert length(y) == n
142
143     S1 = Float64(n)
144     Sx = 0.0
145     Sxx = 0.0
146     Sy = 0.0
147     Sxy = 0.0
148     @inbounds for i in 1:n
149         xi = Float64(x[i]); yi = Float64(y[i])
150         Sx += xi
151         Sxx += xi*xi
152         Sy += yi
153         Sxy += xi*yi
154     end
155
156     det = S1*Sxx - Sx*Sx
157     @assert abs(det) > eps(Float64) * (S1 * Sxx + Sx * Sx) "Singular or
158     ↪ near-singular design matrix (det ≈ 0)"
159     b0 = (Sxx*Sy - Sx*Sxy) / det
160     b1 = (-Sx*Sy + S1*Sxy) / det
161     return b0, b1
162 end
163 """
164     omega_hat_ols(x, y, k; ols_engine=ols_2reg)
165
166 Estimate  $\hat{\omega}_k$  by pooling squared OLS residuals within each type  $k \in \{1, \dots, 5\}$ :
167  $\hat{\omega}_k = (1/N_k) \sum_{i: k_i=k} \hat{e}_i^2$ .
168 Returns a 5-vector  $\hat{\omega}$ .
169 """
170 function omega_hat_ols(
171     x::AbstractVector{<:Real},
172     y::AbstractVector{<:Real},
173     k::AbstractVector{<:Integer};
174     ols_engine::Function = ols_2reg
175 )
176     n = length(x)
177     @assert length(y) == n
178     @assert length(k) == n
179
180     b0, b1 = ols_engine(x, y)
181
182     sse = zeros(Float64, 5)

```

```

183     cnt = zeros(Int, 5)
184
185     @inbounds for i in 1:n
186         ki = Int(k[i])
187         e = Float64(y[i]) - (b0 + b1*Float64(x[i]))
188         sse[ki] += e*e
189         cnt[ki] += 1
190     end
191
192      $\hat{\omega}$  = Vector{Float64}(undef, 5)
193     @inbounds for kk in 1:5
194          $\hat{\omega}$ [kk] = sse[kk] / cnt[kk]    # pooling within type
195         # Groups are assumed to all be populated as in our example.
196         # i.e.  $kk \geq 1 \forall kk$ 
197     end
198     return  $\hat{\omega}$ 
199 end
200
201 """
202     gls_given_omega(x, y, k,  $\hat{\omega}$ )
203
204 Compute GLS for  $y = b0 + b1*x$  with  $\text{Var}(u) = \Omega \otimes I$  (diagonal by type),
205 given  $\hat{\omega} = (\hat{\omega}_1, \dots, \hat{\omega}_5)$ . Uses weights  $w_k = 1/\hat{\omega}_k$ .
206
207 Returns (b0, b1, A11, A12, A22) where  $A = X'\hat{\Sigma}^{-1}X$  has entries  $A_{ij}$ ,
208 useful for inference later without recomputing.
209 """
210 function gls_given_omega(
211     x::AbstractVector{<:Real},
212     y::AbstractVector{<:Real},
213     k::AbstractVector{<:Integer},
214      $\hat{\omega}$ ::AbstractVector{<:Real}
215 )
216     n = length(x)
217     @assert length(y) == n
218     @assert length(k) == n
219     @assert length( $\hat{\omega}$ ) == 5
220
221     #  $A = X'\hat{\Sigma}^{-1}X$  has entries  $A_{ij}$ 
222     A11 = 0.0; A12 = 0.0; A22 = 0.0
223     b1v = 0.0; b2v = 0.0
224
225     @inbounds for i in 1:n
226         ki = Int(k[i])
227         w = 1.0 / Float64( $\hat{\omega}$ [ki])
228         xi = Float64(x[i]); yi = Float64(y[i])
229

```

```

230     A11 += w
231     A12 += w*xi
232     A22 += w*xi*xi
233     b1v += w*yi
234     b2v += w*xi*yi
235 end
236
237 detA = A11*A22 - A12*A12
238
239 b0 = ( A22*b1v - A12*b2v) / detA
240 b1 = (-A12*b1v + A11*b2v) / detA
241
242 return b0, b1, A11, A12, A22
243 end
244
245 """
246     fgls(x, y, k; omega_hat=omega_hat_ols)
247
248 Two-step FGLS:
249 1)  $\hat{\omega} \leftarrow \text{omega\_hat}(x, y, k)$ 
250 2)  $\hat{\beta} \leftarrow \text{gls\_given\_omega}(x, y, k, \hat{\omega})$ 
251
252 Returns (b0, b1, se_b0, se_b1,  $\hat{\omega}$ ) where se_b0 and se_b1 are the standard errors
253 computed from  $\text{Var}(\hat{\beta}) = (X'\hat{\Sigma}^{-1}X)^{-1}$ .
254 """
255 function fgls(
256     x::AbstractVector{<:Real},
257     y::AbstractVector{<:Real},
258     k::AbstractVector{<:Integer};
259     omega_hat = omega_hat_ols
260 )
261      $\hat{\omega}$  = omega_hat(x, y, k)
262     b0, b1, A11, A12, A22 = gls_given_omega(x, y, k,  $\hat{\omega}$ )
263
264     # Compute standard errors from  $(X'\hat{\Sigma}^{-1}X)^{-1}$ 
265     #  $A = [A11 \ A12; A12 \ A22]$ ,  $A^{-1} = (1/\text{det}) * [A22 \ -A12; -A12 \ A11]$ 
266     detA = A11*A22 - A12*A12
267     var_b0 = A22 / detA
268     var_b1 = A11 / detA
269     se_b0 = sqrt(var_b0)
270     se_b1 = sqrt(var_b1)
271
272     return b0, b1, se_b0, se_b1,  $\hat{\omega}$ 
273 end
274
275 """     oracle_gls(x, y, k)
276

```

```

277 GLS estimator using the true variance structure  $\Omega = (4, 9, 16, 25, 36)$ .
278
279 Has the same interface as 'fgls' for compatibility with 'run_exper'.
280 Returns (b0, b1, se_b0, se_b1,  $\omega_{true}$ ) where  $\omega_{true}$  are the known true variances.
281 """
282 function oracle_gls(
283     x::AbstractVector{<:Real},
284     y::AbstractVector{<:Real},
285     k::AbstractVector{<:Integer}
286 )
287     # True variance structure from DGP
288      $\omega_{true}$  = [4.0, 9.0, 16.0, 25.0, 36.0]
289
290     b0, b1, A11, A12, A22 = gls_given_omega(x, y, k,  $\omega_{true}$ )
291
292     # Compute standard errors from  $(X'\Sigma^{-1}X)^{-1}$ 
293     detA = A11*A22 - A12*A12
294     var_b0 = A22 / detA
295     var_b1 = A11 / detA
296     se_b0 = sqrt(var_b0)
297     se_b1 = sqrt(var_b1)
298
299     return b0, b1, se_b0, se_b1,  $\omega_{true}$ 
300 end
301
302 """    t_test(estimate, se, null_value)
303
304 Constructs t-statistic for testing  $H_0: \theta = null\_value$ .
305
306 Returns  $t = (estimate - null\_value) / se$ .
307 """
308 function t_test(estimate::Real, se::Real, null_value::Real)
309     return (Float64(estimate) - Float64(null_value)) / Float64(se)
310 end
311
312
313 # === MONTE CARLO ===
314
315 """
316     run_exper(N, B;  $\beta_0_{true}=-3.0$ ,  $\beta_1_{true}=0.8$ ,  $\beta_1_{null}=0.8$ , gls_engine=fgls,
317         ↪ rng=Random.default_rng())
318
319 Run B simulations with DGP parameters ( $\beta_0_{true}$ ,  $\beta_1_{true}$ ), estimating via specified
320     ↪ GLS method
321 and computing t-statistics for  $H_0: \beta_1 = \beta_1_{null}$ .
322
323 # Arguments

```

```

322 - 'N::Integer': sample size is 5N.
323 - 'B::Integer': number of simulations.
324
325 # Keyword arguments
326 - 'β0_true::Real': true intercept for data generation (default: -3.0).
327 - 'β1_true::Real': true slope for data generation (default: 0.8).
328 - 'β1_null::Real': null hypothesis value for  $\beta_1$  in t-tests (default: 0.8).
329 - 'gls_engine::Function': estimation function taking (x,y,k) and returning
    ↪ (b0,b1,se_b0,se_b1,0) (default: fgls).
330 - 'rng::AbstractRNG': random number generator (default: Random.default_rng()).
331
332 # Returns
333 - 'NamedTuple': contains N, β0_true, β1_true, β1_null, β0 (estimates), β1
    ↪ (estimates), t (statistics).
334 """
335 function run_exper(
336     N::Integer,
337     B::Integer;
338     β0_true::Real = -3.0,
339     β1_true::Real = 0.8,
340     β1_null::Real = 0.8,
341     gls_engine::Function = fgls,
342     rng::AbstractRNG = Random.default_rng(),
343 )
344     β0_vec = Vector{Float64}(undef, B)
345     β1_vec = Vector{Float64}(undef, B)
346     t_vec = Vector{Float64}(undef, B)
347
348     # Preallocate sample arrays once (reused across all B iterations), i.e. written
    ↪ in p1
349     n = 5 * Int(N)
350     x = Vector{Float64}(undef, n)
351     y = Vector{Float64}(undef, n)
352     k = Vector{Int}(undef, n)
353
354     @inbounds for b in 1:B
355         draw_sample!(x, y, k, N; rng=rng, beta0=β0_true, beta1=β1_true)
356         b0, b1, se_b0, se_b1, _ = gls_engine(x, y, k)
357         t = t_test(b1, se_b1, β1_null)
358
359         β0_vec[b] = b0
360         β1_vec[b] = b1
361         t_vec[b] = t
362     end
363
364     return (N=Int(N), β0_true=Float64(β0_true), β1_true=Float64(β1_true),
365         β1_null=Float64(β1_null), β0=β0_vec, β1=β1_vec, t=t_vec)

```

```

366 end
367
368
369 """    plot_t_kde(t_vec, N, beta_val; outdir=..., shade=true, alpha=0.05,
        ↪ null=true, gls_engine=fglgs)
370
371 Plot kernel density estimate of t-statistics with standard normal density overlay.
372
373 Uses non-parametric KDE to show smooth empirical density. As N increases, the
374 empirical density becomes smoother and converges to the standard normal.
375
376 # Arguments
377 - 't_vec::AbstractVector{<:Real}': vector of t-statistics from simulations.
378 - 'N::Integer': sample size parameter (total sample is 5N).
379 - 'beta_val::Real':  $\beta_1$  value used for data generation.
380
381 # Keyword arguments
382 - 'outdir::String': output directory for plot (default:
        ↪ script_dir/../out/plots/ej1).
383 - 'shade::Bool': whether to shade rejection regions (default: true).
384 - 'alpha::Real': significance level for two-sided test (default: 0.05).
385 - 'null::Bool': whether null hypothesis is true (default: true). If false,
        ↪ auto-scales axes to KDE.
386 - 'gls_engine::Function': estimation function used (default: fglgs). Name is
        ↪ appended to filename if not fglgs.
387 """
388 function plot_t_kde(t_vec::AbstractVector{<:Real}, N::Integer, beta_val::Real;
389                   outdir::String=joinpath(@__DIR__, "../out/plots/ej1"),
390                   shade::Bool=true,
391                   alpha::Real=0.05,
392                   null::Bool=true,
393                   gls_engine::Function=fgls)
394     mkpath(outdir)
395
396     # Compute kernel density estimate (non-parametric, smooth empirical density)
397     kde_result = kde(t_vec)
398
399     # Determine axis ranges based on whether null hypothesis is true
400     if null
401         # Fixed axis ranges for visual comparison across different N (under H0)
402         xlims_range = (-5.0, 5.0)
403         ylims_range = (0.0, 0.4)
404     else
405         # Automatic ranges based on KDE support (when H0 is false)
406         xlims_range = (minimum(kde_result.x), maximum(kde_result.x))
407         ylims_range = (0.0, maximum(kde_result.density) * 1.1)
408     end

```

```

409
410 elements = Any[]
411
412 # Pre-compute rejection rate; shade rejection tails if requested
413 rejection_title = ""
414 if shade
415     z_crit = quantile(Normal(0, 1), 1 - alpha/2)
416     rejection_rate = mean(abs.(t_vec) .> z_crit)
417     rejection_title = @sprintf("Rechazo: %.1f\\%", rejection_rate * 100)
418
419     # Left tail: manually close polygon to y=0 so pgfplots fills correctly
420     left_idx = kde_result.x .<= -z_crit
421     if any(left_idx)
422         xs, ys = kde_result.x[left_idx], kde_result.density[left_idx]
423         push!(elements, @pgf PGFPlotsX.Plot(
424             {fill = "gray!30", fill_opacity = 0.4, draw = "none"},
425             Coordinates([xs; xs[end]; xs[1]], [ys; 0.0; 0.0])))
426     end
427
428     # Right tail
429     right_idx = kde_result.x .>= z_crit
430     if any(right_idx)
431         xs, ys = kde_result.x[right_idx], kde_result.density[right_idx]
432         push!(elements, @pgf PGFPlotsX.Plot(
433             {fill = "gray!30", fill_opacity = 0.4, draw = "none"},
434             Coordinates([xs; xs[end]; xs[1]], [ys; 0.0; 0.0])))
435     end
436 end
437
438 # Empirical KDE (solid black)
439 push!(elements, @pgf PGFPlotsX.Plot(
440     {black, solid, line_width = "1.5pt"},
441     Coordinates(collect(kde_result.x), collect(kde_result.density))))
442
443 # Standard normal overlay (dashed gray, semi-transparent)
444 # When null=false this shows the null distribution for reference
445 x_ref = collect(range(xlims_range[1], xlims_range[2], length=200))
446 y_ref = exp.(-x_ref.^2 ./ 2) ./ sqrt(2π)
447 push!(elements, @pgf PGFPlotsX.Plot(
448     {color = "gray", dashed, line_width = "1.5pt", opacity = 0.7},
449     Coordinates(x_ref, y_ref)))
450
451 # Build axis using PGFPlotsX directly for precise dimensional and font control.
452 # width/height set the total figure size including all labels.
453 ax = @pgf Axis(
454     {
455         width = "227pt",

```

```

456         height = "188pt",
457         scale_only_axis = false,
458         xmin = xlims_range[1], xmax = xlims_range[2],
459         ymin = ylims_range[1], ymax = ylims_range[2],
460         xlabel = raw"Estadístico  $t$ ",
461         ylabel = "Densidad",
462         raw"xlabel style={font=\fontsize{10}{12}\selectfont}",
463         raw"ylabel style={font=\fontsize{10}{12}\selectfont}",
464         raw"tick label style={font=\fontsize{8}{9.6}\selectfont}",
465         title = rejection_title,
466         raw"title style={font=\fontsize{10}{12}\selectfont, at={0,1}},
         ↪ anchor=south west, xshift=0pt}",
467     },
468     elements...
469 )
470
471 tp = TikzPicture(ax)
472
473 # Append engine name to filename if not using fgls
474 fname_base = "t_N$(N)_beta$(beta_val)"
475 if gls_engine != fgls
476     engine_name = string(nameof(gls_engine))
477     fname_base *= "_$(engine_name)"
478 end
479
480 pgfsave(joinpath(outdir, fname_base * ".tex"), tp; include_preamble=false)
481 pgfsave(joinpath(outdir, fname_base * ".pdf"), tp)
482 end
483
484
485 # === MONTE CARLO EXPERIMENT ORCHESTRATION ===
486
487 """    run_monte_carlo(B; N_values=...,  $\beta_1$ _true_values=..., alpha_values=...,
         ↪ gls_engine=fgls)
488
489 Run complete Monte Carlo experiment across all combinations of N and  $\beta_1$ _true.
490
491 For each (N,  $\beta_1$ _true) combination:
492 - Runs B simulations via 'run_exper'.
493 - Computes empirical statistics (mean, median, std) for  $\beta_0$  and  $\beta_1$  estimates.
494 - Computes rejection rates at specified significance levels.
495 - Optionally generates t-statistic histograms when  $\beta_1$ _true ==  $\beta_1$ _null (null
         ↪ distribution).
496
497 # Arguments
498 - 'B::Integer': number of Monte Carlo simulations per experiment.
499

```

```

500 # Keyword arguments
501 - 'N_values::Vector{<:Integer}': sample size parameters to test (default: [1, 2, 6,
    ↪ 20, 40, 100]).
502 - 'β1_true_values::Vector{<:Real}': true  $\beta_1$  values for DGP (default: [0.8, 0.0,
    ↪ 0.4]).
503 - 'alpha_values::Vector{<:Real}': significance levels for hypothesis tests
    ↪ (default: [0.01, 0.05]).
504 - 'gls_engine::Function': estimation function taking (x,y,k) and returning
    ↪ (b0,b1,se_b0,se_b1,0) (default: fgls).
505 - 'generate_plots::Bool': whether to generate t-statistic KDE plots (default:
    ↪ true).
506 - 'outdir::String': output directory for plots (default:
    ↪ script_dir/./out/plots/ej1).
507 - 'rng::AbstractRNG': random number generator (default: Random.default_rng()).
508
509 # Returns
510 A named tuple with two elements:
511 - 'param_stats': Vector of NamedTuples containing (N, β1_true, β0_mean, β0_median,
    ↪ β0_std, β1_mean, β1_median, β1_std).
512 - 'rejection_stats': Vector of NamedTuples containing (N, β1_true, alpha,
    ↪ rejection_rate).
513
514 # Notes
515 - β0_true is hardcoded to -3.0.
516 - β1_null is hardcoded to 0.8 for all hypothesis tests.
517 - Plots are only generated when β1_true == β1_null (i.e., when testing size, not
    ↪ power).
518 """
519 function run_monte_carlo(
520     B::Integer;
521     N_values::Vector{<:Integer} = [1, 2, 6, 20, 40, 100],
522     β1_true_values::Vector{<:Real} = [0.8, 0.0, 0.4],
523     alpha_values::Vector{<:Real} = [0.01, 0.05],
524     gls_engine::Function = fgls,
525     generate_plots::Bool = true,
526     outdir::String = joinpath(@__DIR__, "../out/plots/ej1"),
527     rng::AbstractRNG = Random.default_rng()
528 )
529     # Hardcoded parameters as specified
530     β0_true = -3.0
531     β1_null = 0.8
532
533     # Storage for results
534     param_stats = []
535     rejection_stats = []
536

```

```

537 @info "Starting Monte Carlo experiment with B=$B simulations"
538
539 for N in N_values
540     for  $\beta_1$ _true in  $\beta_1$ _true_values
541         @info "Running experiment: N=$N,  $\beta_1$ _true=$ $\beta_1$ _true"
542
543         # Run experiment
544         results = run_exper(N, B;  $\beta_0$ _true= $\beta_0$ _true,  $\beta_1$ _true= $\beta_1$ _true,
545                              $\beta_1$ _null= $\beta_1$ _null, gls_engine=gls_engine, rng=rng)
546
547         # Compute parameter statistics
548          $\beta_0$ _mean = mean(results. $\beta_0$ )
549          $\beta_0$ _median = median(results. $\beta_0$ )
550          $\beta_0$ _std = std(results. $\beta_0$ )
551          $\beta_1$ _mean = mean(results. $\beta_1$ )
552          $\beta_1$ _median = median(results. $\beta_1$ )
553          $\beta_1$ _std = std(results. $\beta_1$ )
554
555         push!(param_stats, (
556             N = N,
557              $\beta_1$ _true =  $\beta_1$ _true,
558              $\beta_0$ _mean =  $\beta_0$ _mean,
559              $\beta_0$ _median =  $\beta_0$ _median,
560              $\beta_0$ _std =  $\beta_0$ _std,
561              $\beta_1$ _mean =  $\beta_1$ _mean,
562              $\beta_1$ _median =  $\beta_1$ _median,
563              $\beta_1$ _std =  $\beta_1$ _std
564         ))
565
566         # Compute rejection rates for each alpha
567         for alpha in alpha_values
568             z_crit = quantile(Normal(0, 1), 1 - alpha/2)
569             rejection_rate = mean(abs.(results.t) .> z_crit)
570
571             push!(rejection_stats, (
572                 N = N,
573                  $\beta_1$ _true =  $\beta_1$ _true,
574                 alpha = alpha,
575                 z_crit = z_crit,
576                 rejection_rate = rejection_rate
577             ))
578         end
579
580         # Generate t-statistic plot (optional)
581         if generate_plots
582             @info "Generating t-statistic plot for N=$N,  $\beta_1$ _true= $\beta_1$ _true"

```

```

583         plot_t_kde(results.t, N,  $\beta_1$ _true; outdir=outdir, null=( $\beta_1$ _true  $\approx$ 
            $\hookrightarrow$   $\beta_1$ _null), gls_engine=gls_engine)
584     end
585 end
586 end
587
588 @info "Monte Carlo experiment complete"
589
590 return (param_stats = param_stats, rejection_stats = rejection_stats)
591 end
592
593
594 # === VIEWING RESULTS ===
595
596 """    print_param_stats(stats)
597
598 Print parameter statistics in a readable tabular format.
599 """
600 function print_param_stats(stats)
601     println("\n" * "="^80)
602     println("PARAMETER ESTIMATES STATISTICS")
603     println("="^80)
604     println(@sprintf("%-6s %-10s %-12s %-12s %-12s %-12s %-12s %-12s",
605                     "N", " $\beta_1$ _true", " $\beta_0$ _mean", " $\beta_0$ _median", " $\beta_0$ _std",
606                     " $\beta_1$ _mean", " $\beta_1$ _median", " $\beta_1$ _std"))
607     println("-"^80)
608
609     for s in stats
610         println(@sprintf("%-6d %-10.2f %-12.4f %-12.4f %-12.4f %-12.4f %-12.4f
            $\hookrightarrow$  %-12.4f",
611                         s.N, s. $\beta_1$ _true, s. $\beta_0$ _mean, s. $\beta_0$ _median, s. $\beta_0$ _std,
612                         s. $\beta_1$ _mean, s. $\beta_1$ _median, s. $\beta_1$ _std))
613     end
614     println("="^80 * "\n")
615 end
616
617 """    print_rejection_stats(stats)
618
619 Print rejection rate statistics in a readable tabular format.
620 """
621 function print_rejection_stats(stats)
622     println("\n" * "="^80)
623     println("REJECTION RATES")
624     println("="^80)
625     println(@sprintf("%-6s %-10s %-8s %-12s %-15s",
626                     "N", " $\beta_1$ _true", " $\alpha$ ", "z_crit", "Reject Rate"))
627     println("-"^80)

```

```

628
629     for s in stats
630         println(@sprintf("%-6d %-10.2f %-8.3f %-12.4f %-15.4f",
631             s.N, s.β1_true, s.alpha, s.z_crit, s.rejection_rate))
632     end
633     println("="^80 * "\n")
634 end
635
636 """    write_param_stats_latex(stats; filename="param_estimates.tex")
637
638 Write parameter statistics to a LaTeX booktabs table with hierarchical column
639 ↪ structure.
640
641 The table organizes results by β1_true values (columns) and N values (rows), with
642 each major column subdivided by parameter (β0, β1) and statistic (mean/std,
643 ↪ median).
644
645 # Arguments
646 - 'stats': Vector of NamedTuples from 'run_monte_carlo' containing parameter
647 ↪ statistics.
648
649 # Keyword arguments
650 - 'filename::String': Output filename (default: "param_estimates.tex").
651 - 'outdir::String': Output directory (default: script_dir/../out/tables/ej1).
652 """
653 function write_param_stats_latex(stats;
654     filename::String = "param_estimates.tex",
655     outdir::String = joinpath(@__DIR__,
656     ↪ "../out/tables/ej1"))
657     mkpath(outdir)
658
659     # Extract unique values and sort
660     beta1_values = sort(unique([s.β1_true for s in stats]))
661     N_values = sort(unique([s.N for s in stats]))
662
663     # Organize data: data[N][β1_true] = (β0_mean, β0_median, β0_std, β1_mean,
664     ↪ β1_median, β1_std)
665     data = Dict()
666     for s in stats
667         if !haskey(data, s.N)
668             data[s.N] = Dict()
669         end
670         data[s.N][s.β1_true] = (s.β0_mean, s.β0_median, s.β0_std,
671             s.β1_mean, s.β1_median, s.β1_std)
672     end
673
674     # Format a number for decimal alignment: split at decimal point

```

```

670  # Returns (integer_part, decimal_part) as strings
671  function split_decimal(x::Real)
672      str = @sprintf("%.4f", x)
673      parts = split(str, '.')
674      if length(parts) == 2
675          return (parts[1], parts[2])
676      else
677          return (str, "0000")
678      end
679  end
680
681  # Format number with math mode for negative sign
682  function fmt_decimal(x::Real)
683      int_part, dec_part = split_decimal(x)
684      if startswith(int_part, "-")
685          int_part = "\$" * int_part * "\$"
686      end
687      return (int_part, dec_part)
688  end
689
690  # Open file and write table
691  open(joinpath(outdir, filename), "w") do io
692      # Begin tabular with decimal-aligned columns (r@{.}l for each number)
693      # Each  $\beta_1$  value has 4 data columns, each split into  $r@{.}l = 8$  actual
694      ↪ columns
695      println(io, "\\begin{tabular}{c} *")
696      ↪ "r@{.}lr@{.}lr@{.}lr@{.}l" ^ length(beta1_values) * "}"
697      println(io, "\\toprule")
698
699      # Top level:  $\beta_1$  values (each spans 8 columns)
700      print(io, "")
701      for  $\beta_1$  in beta1_values
702          print(io, " & \\multicolumn{8}{c}{\\$\\beta_1 = ")
703          print(io,  $\beta_1 == 0.0$  ? "0" : string( $\beta_1$ ))
704          print(io, "\\$}")
705      end
706      println(io, " \\|\\|\\|")
707
708      # Add cmidrules for top level
709      for (i, _) in enumerate(beta1_values)
710          col_start = 2 + 8*(i-1)
711          col_end = col_start + 7
712          print(io, "\\cmidrule(lr){col_start-col_end} ")
713      end
714      println(io)
715
716      # Second level:  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$  (each spans 4 columns)

```

```

715     print(io, "")
716     for _ in beta1_values
717         print(io, " & \\multicolumn{4}{c}{\\$\\widetilde{\\beta}_{0,} \\rightarrow \\mathrm{fgls}\\}$")
718         print(io, " & \\multicolumn{4}{c}{\\$\\widetilde{\\beta}_{1,} \\rightarrow \\mathrm{fgls}\\}$")
719     end
720     println(io, " \\|\\|\\|")
721
722     # Add cmidrules for second level
723     for (i, _) in enumerate(beta1_values)
724         col_start = 2 + 8*(i-1)
725         col_mid = col_start + 3
726         col_end = col_start + 7
727         print(io, "\\cmidrule(lr){$col_start-$col_mid} ")
728         print(io, "\\cmidrule(lr){$(col_mid+1)-$col_end} ")
729     end
730     println(io)
731
732     # Third level: headers for Media (desvío) and Mediana (each spans 2
733     #   ↪ columns)
734     print(io, "\\$5N\\$")
735     for _ in beta1_values
736         for _ in 1:2 #  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$ 
737             print(io, " & \\multicolumn{2}{c}{Media} & \\multicolumn{2}{c}{Mediana}")
738         end
739     end
740     println(io, " \\|\\|\\|")
741
742     # Fourth line: (desvío) under Media columns
743     print(io, "")
744     for _ in beta1_values
745         for _ in 1:2 #  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$ 
746             print(io, " & \\multicolumn{2}{c}{(desvío)} & \\multicolumn{2}{c}{ }")
747         end
748     end
749     println(io, " \\|\\|\\|")
750
751     println(io, "\\midrule")
752
753     # Data rows
754     for N in N_values
755         # First row: means and medians
756         print(io, "\\$(5*N)")
757         for  $\beta_1$  in beta1_values

```

```

757         if haskey(data[N],  $\beta_1$ )
758              $\beta_0$ _mean,  $\beta_0$ _median,  $\beta_0$ _std,  $\beta_1$ _mean,  $\beta_1$ _median,  $\beta_1$ _std =
              ↪ data[N][ $\beta_1$ ]
759             int0m, dec0m = fmt_decimal( $\beta_0$ _mean)
760             int0med, dec0med = fmt_decimal( $\beta_0$ _median)
761             int1m, dec1m = fmt_decimal( $\beta_1$ _mean)
762             int1med, dec1med = fmt_decimal( $\beta_1$ _median)
763             print(io, " & $int0m & $dec0m & $int0med & $dec0med")
764             print(io, " & $int1m & $dec1m & $int1med & $dec1med")
765         else
766             print(io, " & \\multicolumn{2}{c}{--} &
              ↪ \\multicolumn{2}{c}{--}")
767             print(io, " & \\multicolumn{2}{c}{--} &
              ↪ \\multicolumn{2}{c}{--}")
768         end
769     end
770     println(io, " \\\\")
771
772     # Second row: standard deviations in parentheses
773     print(io, "")
774     for  $\beta_1$  in beta1_values
775         if haskey(data[N],  $\beta_1$ )
776             _, _,  $\beta_0$ _std, _, _,  $\beta_1$ _std = data[N][ $\beta_1$ ]
777             int0s, dec0s = split_decimal( $\beta_0$ _std)
778             int1s, dec1s = split_decimal( $\beta_1$ _std)
779             print(io, " & ($int0s & $dec0s) & \\multicolumn{2}{c}{}")
780             print(io, " & ($int1s & $dec1s) & \\multicolumn{2}{c}{}")
781         else
782             print(io, " & \\multicolumn{2}{c}{c}{c} & \\multicolumn{2}{c}{c}{c}")
783             print(io, " & \\multicolumn{2}{c}{c}{c} & \\multicolumn{2}{c}{c}{c}")
784         end
785     end
786     println(io, " \\\\")
787 end
788
789     println(io, "\\bottomrule")
790     println(io, "\\end{tabular}")
791 end
792
793 @info "LaTeX table written to $(joinpath(outdir, filename))"
794 end
795
796 "" write_rejection_stats_latex(stats; filename="rejection_rates.tex")
797
798 Write rejection rate statistics to a LaTeX booktabs table with hierarchical column
  ↪ structure.
799

```

800 *The table organizes results by β_1 -true values (columns) and N values (rows), with*
 801 *each major column subdivided by significance level (1% and 5%).*

802

803 *# Arguments*

804 *- 'stats': Vector of NamedTuples from 'run_monte_carlo' containing rejection*
 ↪ *statistics.*

805

806 *# Keyword arguments*

807 *- 'filename::String': Output filename (default: "rejection_rates.tex").*

808 *- 'outdir::String': Output directory (default: script_dir/../out/tables/ej1).*

809 *"""*

810 **function** write_rejection_stats_latex(stats;

811 *filename::String = "rejection_rates.tex",*

812 *outdir::String = joinpath(@__DIR__,*

↪ *"../out/tables/ej1")*)

813 *mkpath(outdir)*

814

815 *# Extract unique values and sort*

816 *beta1_values = sort(unique([s. β_1 -true for s in stats]))*

817 *N_values = sort(unique([s.N for s in stats]))*

818 *alpha_values = sort(unique([s.alpha for s in stats]))*

819

820 *# Organize data: data[N][β_1 -true][alpha] = rejection_rate*

821 *data = Dict()*

822 **for** s in stats

823 *if !haskey(data, s.N)*

824 *data[s.N] = Dict()*

825 *end*

826 *if !haskey(data[s.N], s. β_1 -true)*

827 *data[s.N][s. β_1 -true] = Dict()*

828 *end*

829 *data[s.N][s. β_1 -true][s.alpha] = s.rejection_rate*

830 **end**

831

832 *# Format rejection rate as percentage with smart rounding*

833 *# Strips trailing zeros: 100.00 → 100, 97.50 → 97.5, 97.06 → 97.06*

834 **function** split_decimal_rate(x::Real, include_pct::Bool=true)

835 *pct = x * 100.0*

836 *str = @sprintf("%.2f", pct)*

837 *# Strip trailing zeros and decimal point if integer*

838 *str = replace(str, r"\.?0+\$" ⇒ "")*

839 *# Split at decimal point (if still present)*

840 *parts = split(str, '.')*

841 *if length(parts) == 2*

842 *# Has decimal part - include the dot in the decimal part*

843 *if include_pct*

844 *return (parts[1], "." * parts[2] * "\\%")*

```

845         else
846             return (parts[1], "." * parts[2])
847         end
848     else
849         # No decimal point (integer) - empty decimal part
850         if include_pct
851             return (str, "\\%")
852         else
853             return (str, "")
854         end
855     end
856 end
857
858 # Open file and write table
859 open(joinpath(outdir, filename), "w") do io
860     # Each  $\beta_1$  value has 2 significance levels, each split into  $r@{\}l = 4$  actual
861     ↪ columns
862     println(io, "\\begin{tabular}{c} * "r@{\}lr@{\}l"^length(beta1_values) * "{")
863     println(io, "\\toprule")
864
865     # Top level:  $\beta_1$  values (each spans 4 columns)
866     print(io, "")
867     for  $\beta_1$  in beta1_values
868         print(io, " & \\multicolumn{4}{c}{\\$\\beta_1 = ")
869         print(io,  $\beta_1 == 0.0$  ? "0" : string( $\beta_1$ ))
870         print(io, "\\$}")
871     end
872     println(io, " \\\\")
873
874     # Add cmidrules for top level
875     for (i, _) in enumerate(beta1_values)
876         col_start = 2 + 4*(i-1)
877         col_end = col_start + 3
878         print(io, "\\cmidrule(lr){$col_start-$col_end} ")
879     end
880     println(io)
881
882     # Second level: significance levels (each spans 2 columns)
883     print(io, "\\$5N\\$")
884     for _ in beta1_values
885         print(io, " & \\multicolumn{2}{c}{\\$1\\%\\$}")
886         print(io, " & \\multicolumn{2}{c}{\\$5\\%\\$}")
887     end
888     println(io, " \\\\")
889
890     println(io, "\\midrule")

```

```

891     # Data rows
892     for (row_idx, N) in enumerate(N_values)
893         print(io, "$(5*N)")
894         is_first_row = (row_idx == 1)
895
896         for  $\beta_1$  in beta1_values
897             for  $\alpha$  in alpha_values
898                 if haskey(data[N],  $\beta_1$ ) && haskey(data[N][ $\beta_1$ ],  $\alpha$ )
899                     rate = data[N][ $\beta_1$ ][ $\alpha$ ]
900                     int_part, dec_part = split_decimal_rate(rate, is_first_row)
901                     print(io, " & $int_part & $dec_part")
902                 else
903                     print(io, " & \\multicolumn{2}{c}{--}")
904                 end
905             end
906         end
907         println(io, " \\\\")
908     end
909
910     println(io, "\\bottomrule")
911     println(io, "\\end{tabular}")
912 end
913
914 @info "LaTeX table written to $(joinpath(outdir, filename))"
915 end
916
917 """    write_param_stats_comparison_latex(stats_fgls, stats_gls;
918 ↪ filename="param_estimates_comparison.tex")
919
920 Write parameter statistics comparison between FGLS and GLS to a LaTeX booktabs
921 ↪ table.
922
923 The table organizes results by estimation method (columns) and N values (rows),
924 ↪ with
925 each major column subdivided by parameter ( $\tilde{\beta}_0$ ,  $\tilde{\beta}_1$ ) and statistic (mean/std,
926 ↪ median).
927 Only includes results for  $\beta_1\text{-true} = 0.8$ .
928
929 # Arguments
930 - 'stats_fgls': Vector of NamedTuples from 'run_monte_carlo' with FGLS results.
931 - 'stats_gls': Vector of NamedTuples from 'run_monte_carlo' with GLS results.
932
933 # Keyword arguments
934 - 'filename::String': Output filename (default: "param_estimates_comparison.tex").
935 - 'outdir::String': Output directory (default: script_dir/../../out/tables/ej1).
936 """
937 function write_param_stats_comparison_latex(stats_fgls, stats_gls;

```

```

934         filename::String =
935             ↪ "param_estimates_comparison.tex",
936         outdir::String = joinpath(@__DIR__,
937             ↪ "../out/tables/ej1"))
938     mkpath(outdir)
939
940     # Filter for  $\beta_1_{\text{true}} = 0.8$  and extract  $N$  values
941     stats_fgls_filtered = filter(s -> s. $\beta_1_{\text{true}} \approx 0.8$ , stats_fgls)
942     stats_gls_filtered = filter(s -> s. $\beta_1_{\text{true}} \approx 0.8$ , stats_gls)
943     N_values = sort(unique([s.N for s in stats_fgls_filtered]))
944
945     # Organize data: data[method][N] = ( $\beta_0_{\text{mean}}$ ,  $\beta_0_{\text{median}}$ ,  $\beta_0_{\text{std}}$ ,  $\beta_1_{\text{mean}}$ ,
946     ↪  $\beta_1_{\text{median}}$ ,  $\beta_1_{\text{std}}$ )
947     data = Dict{"FGLS" => Dict(), "GLS" => Dict()}
948
949     for s in stats_fgls_filtered
950         data["FGLS"][s.N] = (s. $\beta_0_{\text{mean}}$ , s. $\beta_0_{\text{median}}$ , s. $\beta_0_{\text{std}}$ , s. $\beta_1_{\text{mean}}$ ,
951             ↪ s. $\beta_1_{\text{median}}$ , s. $\beta_1_{\text{std}}$ )
952     end
953
954     for s in stats_gls_filtered
955         data["GLS"][s.N] = (s. $\beta_0_{\text{mean}}$ , s. $\beta_0_{\text{median}}$ , s. $\beta_0_{\text{std}}$ , s. $\beta_1_{\text{mean}}$ ,
956             ↪ s. $\beta_1_{\text{median}}$ , s. $\beta_1_{\text{std}}$ )
957     end
958
959     methods = ["FGLS", "GLS"]
960
961     # Format a number for decimal alignment: split at decimal point
962     # Returns (integer_part, decimal_part) as strings
963     function split_decimal(x::Real)
964         str = @sprintf("%.4f", x)
965         parts = split(str, '.')
966         if length(parts) == 2
967             return (parts[1], parts[2])
968         else
969             return (str, "0000")
970         end
971     end
972
973     # Format number with math mode for negative sign
974     function fmt_decimal(x::Real)
975         int_part, dec_part = split_decimal(x)
976         if startswith(int_part, "-")
977             int_part = "\$" * int_part * "\$"
978         end
979         return (int_part, dec_part)
980     end

```

```

976 # Open file and write table
977 open(joinpath(outdir, filename), "w") do io
978     # Begin tabular with decimal-aligned columns (r@{.}l for each number)
979     # Each method has 4 data columns, each split into r@{.}l = 8 actual columns
980     println(io, "\\begin{tabular}{c} *
          ↪ "r@{.}lr@{.}lr@{.}lr@{.}l"^length(methods) * "{")
981     println(io, "\\toprule")
982
983     # Top level: Method names (each spans 8 columns)
984     print(io, "")
985     for method in methods
986         print(io, " & \\multicolumn{8}{c}{{$method}}")
987     end
988     println(io, " \\\\"")
989
990     # Add cmidrules for top level
991     for (i, _) in enumerate(methods)
992         col_start = 2 + 8*(i-1)
993         col_end = col_start + 7
994         print(io, "\\cmidrule(lr){$col_start-$col_end} ")
995     end
996     println(io)
997
998     # Second level:  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$  (each spans 4 columns)
999     print(io, "")
1000     for _ in methods
1001         print(io, " & \\multicolumn{4}{c}{\\$\\widetilde{\\beta}_0\\$}")
1002         print(io, " & \\multicolumn{4}{c}{\\$\\widetilde{\\beta}_1\\$}")
1003     end
1004     println(io, " \\\\"")
1005
1006     # Add cmidrules for second level
1007     for (i, _) in enumerate(methods)
1008         col_start = 2 + 8*(i-1)
1009         col_mid = col_start + 3
1010         col_end = col_start + 7
1011         print(io, "\\cmidrule(lr){$col_start-$col_mid} ")
1012         print(io, "\\cmidrule(lr){$(col_mid+1)-$col_end} ")
1013     end
1014     println(io)
1015
1016     # Third level: headers for Media (desvío) and Mediana (each spans 2
          ↪ columns)
1017     print(io, "\\$5N\\$")
1018     for _ in methods
1019         for _ in 1:2 #  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$ 

```

```

1020         print(io, " & \\multicolumn{2}{c}{Media} &
        ↪ \\multicolumn{2}{c}{Mediana}")
1021     end
1022 end
1023 println(io, " \\|\\|\\|")
1024
1025 # Fourth line: (desvío) under Media columns
1026 print(io, "")
1027 for _ in methods
1028     for _ in 1:2 #  $\tilde{\beta}_0$  and  $\tilde{\beta}_1$ 
1029         print(io, " & \\multicolumn{2}{c}{(desvío)} &
        ↪ \\multicolumn{2}{c}{})")
1030     end
1031 end
1032 println(io, " \\|\\|\\|")
1033
1034 println(io, "\\midrule")
1035
1036 # Data rows
1037 for N in N_values
1038     # First row: means and medians
1039     print(io, "$(5*N)")
1040     for method in methods
1041         if haskey(data[method], N)
1042              $\beta_0$ _mean,  $\beta_0$ _median,  $\beta_0$ _std,  $\beta_1$ _mean,  $\beta_1$ _median,  $\beta_1$ _std =
            ↪ data[method][N]
1043             int0m, dec0m = fmt_decimal( $\beta_0$ _mean)
1044             int0med, dec0med = fmt_decimal( $\beta_0$ _median)
1045             int1m, dec1m = fmt_decimal( $\beta_1$ _mean)
1046             int1med, dec1med = fmt_decimal( $\beta_1$ _median)
1047             print(io, " & $int0m & $dec0m & $int0med & $dec0med")
1048             print(io, " & $int1m & $dec1m & $int1med & $dec1med")
1049         else
1050             print(io, " & \\multicolumn{2}{c}{--} &
            ↪ \\multicolumn{2}{c}{--}")
1051             print(io, " & \\multicolumn{2}{c}{--} &
            ↪ \\multicolumn{2}{c}{--}")
1052         end
1053     end
1054     println(io, " \\|\\|\\|")
1055
1056 # Second row: standard deviations in parentheses
1057 print(io, "")
1058 for method in methods
1059     if haskey(data[method], N)
1060         _, _,  $\beta_0$ _std, _, _,  $\beta_1$ _std = data[method][N]
1061         int0s, dec0s = split_decimal( $\beta_0$ _std)

```

```

1062         int1s, dec1s = split_decimal( $\beta$ 1_std)
1063         print(io, " & ($int0s & $dec0s) & \\multicolumn{2}{c}{}")
1064         print(io, " & ($int1s & $dec1s) & \\multicolumn{2}{c}{}")
1065     else
1066         print(io, " & \\multicolumn{2}{c}{c} & \\multicolumn{2}{c}{c}")
1067         print(io, " & \\multicolumn{2}{c}{c} & \\multicolumn{2}{c}{c}")
1068     end
1069 end
1070 println(io, " \\|\\|\\|")
1071 end
1072
1073     println(io, "\\bottomrule")
1074     println(io, "\\end{tabular}")
1075 end
1076
1077 @info "LaTeX table written to $(joinpath(outdir, filename))"
1078 end
1079
1080 """    write_rejection_stats_comparison_latex(stats_fgls, stats_gls;
1081     ↪ filename="rejection_rates_comparison.tex")
1082
1083 Write rejection rate statistics comparison between FGLS and GLS to a LaTeX booktabs
1084     ↪ table.
1085
1086 The table organizes results by estimation method (columns) and N values (rows),
1087     ↪ with
1088 each major column subdivided by significance level (1% and 5%).
1089 Only includes results for  $\beta_1\text{-true} = 0.8$ .
1090
1091 # Arguments
1092 - 'stats_fgls': Vector of NamedTuples from 'run_monte_carlo' with FGLS results.
1093 - 'stats_gls': Vector of NamedTuples from 'run_monte_carlo' with GLS results.
1094
1095 # Keyword arguments
1096 - 'filename::String': Output filename (default: "rejection_rates_comparison.tex").
1097 - 'outdir::String': Output directory (default: script_dir/../out/tables/ej1).
1098 """
1099 function write_rejection_stats_comparison_latex(stats_fgls, stats_gls;
1100     filename::String =
1101         ↪ "rejection_rates_comparison.tex",
1102     outdir::String = joinpath(@__DIR__,
1103         ↪ "../out/tables/ej1"))
1104     mkpath(outdir)
1105
1106     # Filter for  $\beta_1\text{-true} = 0.8$ 
1107     stats_fgls_filtered = filter(s -> s. $\beta$ 1_true  $\approx$  0.8, stats_fgls)
1108     stats_gls_filtered = filter(s -> s. $\beta$ 1_true  $\approx$  0.8, stats_gls)

```

```

1104
1105 N_values = sort(unique([s.N for s in stats_fgls_filtered]))
1106 alpha_values = sort(unique([s.alpha for s in stats_fgls_filtered]))
1107
1108 # Organize data: data[method][N][alpha] = rejection_rate
1109 data = Dict("FGLS" ⇒ Dict(), "GLS" ⇒ Dict())
1110
1111 for s in stats_fgls_filtered
1112     if !haskey(data["FGLS"], s.N)
1113         data["FGLS"][s.N] = Dict()
1114     end
1115     data["FGLS"][s.N][s.alpha] = s.rejection_rate
1116 end
1117
1118 for s in stats_gls_filtered
1119     if !haskey(data["GLS"], s.N)
1120         data["GLS"][s.N] = Dict()
1121     end
1122     data["GLS"][s.N][s.alpha] = s.rejection_rate
1123 end
1124
1125 methods = ["FGLS", "GLS"]
1126
1127 # Format rejection rate as percentage with smart rounding
1128 # Strips trailing zeros: 100.00 → 100, 97.50 → 97.5, 97.06 → 97.06
1129 function split_decimal_rate(x::Real, include_pct::Bool=true)
1130     pct = x * 100.0
1131     str = @sprintf("%.2f", pct)
1132     # Strip trailing zeros and decimal point if integer
1133     str = replace(str, r"\.?0+$" ⇒ "")
1134     # Split at decimal point (if still present)
1135     parts = split(str, '.')
1136     if length(parts) == 2
1137         # Has decimal part - include the dot in the decimal part
1138         if include_pct
1139             return (parts[1], "." * parts[2] * "\\%")
1140         else
1141             return (parts[1], "." * parts[2])
1142         end
1143     else
1144         # No decimal point (integer) - empty decimal part
1145         if include_pct
1146             return (str, "\\%")
1147         else
1148             return (str, "")
1149         end
1150     end
end

```

```

1151 end
1152
1153 # Open file and write table
1154 open(joinpath(outdir, filename), "w") do io
1155     # Each method has 2 significance levels, each split into  $r@{}l = 4$  actual
1156     ↪ columns
1157     println(io, "\\begin{tabular}{c} * "r@{}lr@{}l"^length(methods) * "{")
1158     println(io, "\\toprule")
1159
1160     # Top level: Method names (each spans 4 columns)
1161     print(io, "")
1162     for method in methods
1163         print(io, " & \\multicolumn{4}{c}{\$method}")
1164     end
1165     println(io, " \\\\")
1166
1167     # Add cmidrules for top level
1168     for (i, _) in enumerate(methods)
1169         col_start = 2 + 4*(i-1)
1170         col_end = col_start + 3
1171         print(io, "\\cmidrule(lr){\$col_start-\$col_end} ")
1172     end
1173     println(io)
1174
1175     # Second level: significance levels (each spans 2 columns)
1176     print(io, "\\$5N\$")
1177     for _ in methods
1178         print(io, " & \\multicolumn{2}{c}{\$1\\%\$}")
1179         print(io, " & \\multicolumn{2}{c}{\$5\\%\$}")
1180     end
1181     println(io, " \\\\")
1182
1183     println(io, "\\midrule")
1184
1185     # Data rows
1186     for (row_idx, N) in enumerate(N_values)
1187         print(io, "\\$(5*N)")
1188         is_first_row = (row_idx == 1)
1189
1190         for method in methods
1191             for  $\alpha$  in alpha_values
1192                 if haskey(data[method], N) && haskey(data[method][N],  $\alpha$ )
1193                     rate = data[method][N][ $\alpha$ ]
1194                     int_part, dec_part = split_decimal_rate(rate, is_first_row)
1195                     print(io, " & \$int_part & \$dec_part")
1196                 else
1197                     print(io, " & \\multicolumn{2}{c}{--}")
1198                 end
1199             end
1200         end
1201     end
1202 end

```

```

1197         end
1198     end
1199 end
1200     println(io, " \\\\")
1201 end
1202
1203     println(io, "\\bottomrule")
1204     println(io, "\\end{tabular}")
1205 end
1206
1207 @info "LaTeX table written to $(joinpath(outdir, filename))"
1208 end
1209
1210
1211 # === REJECTION RATE BY SAMPLE SIZE PLOTS ===
1212
1213 """
1214     plot_rejection_rates_by_n(B;
1215                               N_grid=1:1:100,
1216                                $\beta_1$ _values=[0.0, 0.4, 0.8],
1217                               alpha_values=[0.01, 0.05],
1218                               gls_engine=fgls,
1219                               outdir=joinpath(@__DIR__, "../out/plots/ej1"))
1220
1221 Generate plots showing rejection rates as a function of sample size for GLS t-test.
1222
1223 Creates one plot per significance level, with separate lines for each  $\beta_1$  value.
1224 Each plot shows dots at data points connected by lines, plus a horizontal reference
1225 line at the nominal significance level.
1226
1227 # Arguments
1228 - 'B::Integer': Number of Monte Carlo replications per ( $N$ ,  $\beta_1$ ) combination.
1229
1230 # Keyword arguments
1231 - 'N_grid': Sample sizes to test (default: 1:1:100), where  $n = 5N$ .
1232 - ' $\beta_1$ _values::Vector{<:Real}': True  $\beta_1$  values to test (default: [0.0, 0.4, 0.8]).
1233 - 'alpha_values::Vector{<:Real}': Significance levels for plots (default: [0.01,
1234   ↪ 0.05]).
1235 - 'gls_engine::Function': estimation function (default: fgls).
1236 - 'outdir::String': Output directory for plots.
1237 """
1238 function plot_rejection_rates_by_n(
1239     B::Integer;
1240     N_grid = 1:1:100,
1241      $\beta_1$ _values::Vector{<:Real} = [0.0, 0.4, 0.8],
1242     alpha_values::Vector{<:Real} = [0.01, 0.05],
1243     gls_engine::Function = fgls,

```

```

1243  outdir::String = joinpath(@__DIR__, "../out/plots/ej1")
1244 )
1245 # Run Monte Carlo with specified N-grid
1246 @info "Running Monte Carlo for rejection rate plots (N =
      ↪ $(N_grid[1]):$(step(N_grid)):$(N_grid[end]))"
1247 N_vals = collect(N_grid)
1248 results = run_monte_carlo(
1249     B;
1250     N_values = N_vals,
1251     β1_true_values = β1_values,
1252     alpha_values = alpha_values,
1253     gls_engine = gls_engine,
1254     generate_plots = false
1255 )
1256 rejection_stats = results.rejection_stats
1257
1258 # Extract rejection rates for a given α level
1259 function extract_rates_by_beta(stats, N_vals, α_target)
1260     betas = sort(unique([s.β1_true for s in stats]))
1261     rates = Dict{<math>\beta</math>, Float64{}}()
1262     for β in betas
1263         rates[β] = Float64{}}()
1264         for N in N_vals
1265             idx = findfirst(s -> s.N == N && s.β1_true ≈ β && s.alpha ≈
      ↪ α_target, stats)
1266             if idx != nothing
1267                 push!(rates[β], stats[idx].rejection_rate)
1268             else
1269                 push!(rates[β], NaN)
1270             end
1271         end
1272     end
1273     return rates
1274 end
1275
1276 # Plot styling
1277 beta_labels = Dict{<math>\beta</math>, String}()
1278     0.8 => "β<sub>1</sub> = 0.8 (H<sub>0</sub> verdadera)",
1279     0.4 => "β<sub>1</sub> = 0.4",
1280     0.0 => "β<sub>1</sub> = 0.0")
1281 beta_colors = Dict{<math>\beta</math>, Color{<math>\alpha</math>}}()
1282     0.8 => :blue, 0.4 => :red, 0.0 => :green)
1283 beta_markers = Dict{<math>\beta</math>, Symbol}()
1284     0.8 => :circle, 0.4 => :square, 0.0 => :diamond)
1285
1286 mkpath(outdir)
1287
1288 # Create one plot for each significance level
1289 for α_level in alpha_values
1290     @info "Creating rejection rate plot for α = $α_level"

```

```

1288
1289     rates_by_beta = extract_rates_by_beta(rejection_stats, N_vals,  $\alpha$ _level)
1290
1291     # Convert N to n (n = 5N) for x-axis
1292     n_vals = 5 .* N_vals
1293
1294     # Create plot
1295     p = plot(
1296         xlabel = L"Tamaño de muestra ( $n$ )",
1297         ylabel = "Tasa de rechazo",
1298         legend = :topright,
1299         size = (600, 400),
1300         ylims = (0, 1),
1301         grid = true
1302     )
1303
1304     # Plot each  $\beta$  value as dots connected by lines
1305     for  $\beta$  in sort(collect(keys(rates_by_beta)), rev=true) # Sort descending so
1306          $\hookrightarrow$  0.8 appears first
1307         plot!(p, n_vals, rates_by_beta[ $\beta$ ],
1308             label = beta_labels[ $\beta$ ],
1309             color = beta_colors[ $\beta$ ],
1310             marker = beta_markers[ $\beta$ ],
1311             markersize = 4,
1312             linewidth = 2,
1313             linestyle = :solid)
1314
1315     end
1316
1317     # Add horizontal reference line at nominal significance level
1318     hline!(p, [ $\alpha$ _level],
1319         linestyle = :dash,
1320         color = :gray,
1321         alpha = 0.5,
1322         linewidth = 1.5,
1323         label = "")
1324
1325     # Save plot with  $\alpha$  in filename
1326      $\alpha$ _str = replace(string( $\alpha$ _level), "."  $\Rightarrow$  "")
1327     fname_base = "rejection_rate_by_n_alpha$( $\alpha$ _str)"
1328     savefig(p, joinpath(outdir, fname_base * ".tex"))
1329     savefig(p, joinpath(outdir, fname_base * ".pdf"))
1330
1331     @info "Plot saved: $(fname_base).pdf"
1332
1333 end
1334
1335 @info "All rejection rate plots saved to $outdir"
1336 end

```

```

1334
1335
1336 # === HEATMAP: REJECTION RATE AS FUNCTION OF  $\beta_1$  AND N ===
1337
1338 """
1339     plot_rejection_rate_heatmap(B;
1340                                  $\beta_1$ _grid=0.70:0.01:0.90,
1341                                 N_grid=1:2:100,
1342                                 test_alpha=0.01,
1343                                 gls_engine=fgls,
1344                                 resolution=1.0,
1345                                 outdir=joinpath(@__DIR__, "../out/plots/ej1"))
1346
1347 Generate heatmap showing empirical rejection rates as a function of  $\beta_1$  and sample
    ↪ size.
1348
1349 Creates a heatmap with  $n$  (sample size) on x-axis,  $\beta_1$  on y-axis, and color encoding
1350 the empirical rejection rate at each grid point. The human visual system perceives
    ↪ the
1351 implied iso-rejection contours from the color gradient directly.
1352
1353 # Arguments
1354 - 'B::Integer': Number of Monte Carlo replications per ( $N$ ,  $\beta_1$ ) combination.
1355
1356 # Keyword arguments
1357 - ' $\beta_1$ _grid': Grid of  $\beta_1$  values to test (default: 0.70:0.01:0.90).
1358 - 'N_grid': Grid of  $N$  values to test, where  $n = 5N$  (default: 1:2:100).
1359 - 'test_alpha::Real': Significance level for the test (default: 0.01).
1360 - 'gls_engine::Function': estimation function (default: fgls).
1361 - 'resolution::Real': Resolution multiplier - higher values create finer grids
    ↪ (default: 1.0).
1362 - 'outdir::String': Output directory for plots.
1363 """
1364 function plot_rejection_rate_heatmap(
1365     B::Integer;
1366      $\beta_1$ _grid = 0.70:0.01:0.90,
1367     N_grid = 1:2:100,
1368     test_alpha::Real = 0.01,
1369     gls_engine::Function = fgls,
1370     resolution::Real = 1.0,
1371     outdir::String = joinpath(@__DIR__, "../out/plots/ej1")
1372 )
1373     # Apply resolution scaling to grids
1374     if resolution != 1.0
1375          $\beta_1$ _min,  $\beta_1$ _max = extrema( $\beta_1$ _grid)
1376          $\beta_1$ _step = step( $\beta_1$ _grid) / resolution
1377          $\beta_1$ _grid =  $\beta_1$ _min: $\beta_1$ _step: $\beta_1$ _max

```

```

1378
1379     N_min, N_max = extrema(N_grid)
1380     N_step = max(1, round(Int, step(N_grid) / resolution))
1381     N_grid = N_min:N_step:N_max
1382 end
1383
1384 # Ensure  $N \geq 1$  (so  $n = 5N \geq 5$ )
1385 N_min = first(N_grid)
1386 if N_min < 1
1387     error("N must be at least 1 ( $n = 5N$  must be  $\geq 5$ )")
1388 end
1389
1390 # Convert ranges to vectors
1391  $\beta_1$ _vals = collect( $\beta_1$ _grid)
1392 N_vals = collect(N_grid)
1393
1394 @info "Running Monte Carlo for contour plot"
1395 @info "  $\beta_1$  grid: $(length( $\beta_1$ _vals)) values from $( $\beta_1$ _vals[1]) to
1396     ↪ $( $\beta_1$ _vals[end])"
1397 @info " N grid: $(length(N_vals)) values from $(N_vals[1]) to $(N_vals[end])"
1398 @info " Total experiments: $(length( $\beta_1$ _vals) × length(N_vals))"
1399
1400 # Run Monte Carlo on the grid
1401 results = run_monte_carlo(
1402     B;
1403     N_values = N_vals,
1404      $\beta_1$ _true_values =  $\beta_1$ _vals,
1405     alpha_values = [test_alpha],
1406     gls_engine = gls_engine,
1407     generate_plots = false
1408 )
1409 rejection_stats = results.rejection_stats
1410
1411 # Build rejection rate matrix: rows = N, cols =  $\beta_1$ 
1412 rejection_matrix = Matrix{Float64}(undef, length(N_vals), length( $\beta_1$ _vals))
1413
1414 for (i, N) in enumerate(N_vals)
1415     for (j,  $\beta_1$ ) in enumerate( $\beta_1$ _vals)
1416         idx = findfirst(s -> s.N == N && s. $\beta_1$ _true ≈  $\beta_1$  && s.alpha ≈
1417             ↪ test_alpha, rejection_stats)
1418         if idx !== nothing
1419             rejection_matrix[i, j] = rejection_stats[idx].rejection_rate
1420         else
1421             rejection_matrix[i, j] = NaN
1422         end
1423     end
1424 end

```

```

1423
1424   # Convert N to n for plotting
1425   n_vals = 5 .* N_vals
1426
1427   # Heatmap: color encodes empirical rejection rate at each (n,  $\beta_1$ ) grid point
1428   # Compute x-axis ticks so the minimum n value is always labelled
1429   x_tick_step = max(10, ceil(Int, (last(n_vals) - first(n_vals)) / 5 / 10) * 10)
1430   x_ticks = sort(unique(vcat(first(n_vals),
1431                               ↪ collect(first(n_vals)+x_tick_step:x_tick_step:last(n_vals))))))
1431
1432   p = heatmap(
1433       n_vals,  $\beta_1$ _vals, rejection_matrix',
1434       xlabel = L"Tamaño de muestra ($5N$)",
1435       ylabel = L"Valor verdadero de  $\beta_1$ ",
1436       title = "",
1437       colorbar_title = "",
1438       color = cgrad([:black, :white]),
1439       size = (700, 500),
1440       clim = (0.0, 1.0),
1441       grid = false,
1442       framestyle = :box,
1443       xticks = x_ticks
1444   )
1445
1446   # Mark the null hypothesis value  $\beta_1 = 0.8$  for reference
1447   hline!(p, [0.8],
1448         linestyle = :dash,
1449         color = :white,
1450         linewidth = 0.8,
1451         label = "",
1452         alpha = 0.9)
1453
1454   mkpath(outdir)
1455
1456    $\alpha$ _str = replace(string(test_alpha), "." ⇒ "")
1457   fname_base = "rejection_rate_heatmap_alpha$( $\alpha$ _str)"
1458   savefig(p, joinpath(outdir, fname_base * ".tex"))
1459   savefig(p, joinpath(outdir, fname_base * ".pdf"))
1460
1461   @info "Heatmap saved: $(fname_base).pdf"
1462   @info "Plot saved to $outdir"
1463 end
1464
1465
1466 # === EXECUTION ===
1467
1468 # Generate high resolution heatmap (used in Figure ej-1-rejection-rate-heatmap)

```

```

1469 plot_rejection_rate_heatmap(10000, resolution = 20.0)
1470
1471 # Run with FGLS (default) - generates t-statistic plots for FGLS
1472 results_fgls = run_monte_carlo(5000, )
1473
1474 # Run with GLS (true omega) - generates t-statistic plots for GLS
1475 results_gls = run_monte_carlo(5000, gls_engine=oracle_gls, generate_plots=true)
1476
1477 # Generate comparison tables (FGLS vs GLS for  $\beta_1\text{-true} = 0.8$ )
1478 write_param_stats_comparison_latex(results_fgls.param_stats,
  ↪ results_gls.param_stats)
1479 write_rejection_stats_comparison_latex(results_fgls.rejection_stats,
  ↪ results_gls.rejection_stats)
1480
1481 # Generate main FGLS tables
1482 param_stats = results_fgls.param_stats
1483 rejection_stats = results_fgls.rejection_stats
1484 write_param_stats_latex(param_stats)
1485 write_rejection_stats_latex(rejection_stats)

```

A.2. Ejercicio 2. El contenido del archivo ej2.jl es el siguiente.

```

1 # =====
2 # TRABAJO FINAL ECONOMETRIA
3 # Ejercicio 2: Test de Heterocedasticidad de White
4 #
5 # Autor: Felipe Tappata
6 # Fecha: Febrero 2026
7 # =====
8
9 # Load dependencies
10 using Random, Statistics
11 using LinearAlgebra
12 using Printf, LaTeXStrings
13 using Distributions
14 using StaticArrays
15 using Plots, KernelDensity
16 import PGFPlotsX
17
18 # Set plotting backend
19 function __init_plots__()
20     pgfplotsx()
21     default(tex_output_standalone=false)
22 end
23 __init_plots__()
24
25 # Set seed

```

```

26 const SEED = 8869
27 Random.seed!(SEED)
28
29
30
31 # === DATA GENERATION ===
32
33 #  $x_1$  base pattern: 18 evenly-spaced points in  $[-1,1]$  plus endpoints -1.1 and 1.1
34 const X1_BASE = vcat(-1.1, range(-1.0, 1.0, length=18), 1.1)
35
36 """
37     draw_sample(n::Integer, design::Integer;
38               beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
39               rng::AbstractRNG = Random.default_rng())
40
41 Generate one sample from the heteroskedastic model:
42      $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \sqrt{v_i} u_i$ 
43
44 # Designs:
45 - Design 0:  $u_i \sim N(0,1)$ ,  $v_i = 1$  (homoskedastic normal)
46 - Design 1:  $u_i \sim N(0,1)$ ,  $v_i = \exp(0.25x_{1i} + 0.25x_{2i})$  (heteroskedastic normal)
47 - Design 2:  $u_i \sim t_5$ ,  $v_i = \exp(0.25x_{1i} + 0.25x_{2i})$  (heteroskedastic non-normal)
48
49 # Arguments
50 - 'n::Integer': sample size, must be a multiple of 20.
51 - 'design::Integer': design number (0, 1, or 2).
52
53 # Keyword arguments
54 - 'beta::AbstractVector{<:Real}': coefficient vector  $[\beta_0, \beta_1, \beta_2]$  (default: [1.0,
55   ↪ 1.0, 1.0]).
56 - 'rng::AbstractRNG': random number generator (default: Random.default_rng()).
57
58 # Returns
59 - 'X::Matrix{Float64}': design matrix with intercept column ( $n \times 3$ ).
60 - 'y::Vector{Float64}': dependent variable (length n).
61
62 # Notes
63  $x_1$ : 18 evenly-spaced points in  $[-1,1]$  plus endpoints -1.1 and 1.1 (deterministic);
64   ↪ repeats  $m = n/20$  times.
65  $x_2$ : 20 fresh random draws from standard normal per repetition (n draws total).
66 """
67 function draw_sample(
68     n::Integer,
69     design::Integer;
70     beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
71     rng::AbstractRNG = Random.default_rng(),
72 )

```

```

71  # Validate inputs
72  @assert n % 20 == 0 "Sample size n must be a multiple of 20"
73  @assert design ∈ (0, 1, 2) "Design must be 0, 1, or 2"
74  @assert length(beta) == 3 "beta must have 3 elements: [ $\beta_0$ ,  $\beta_1$ ,  $\beta_2$ ]"
75
76  n = Int(n)
77  m = div(n, 20) # number of repetitions
78
79  # Allocate output
80  X = Matrix{Float64}(undef, n, 3)
81  y = Vector{Float64}(undef, n)
82
83  # Fill design matrix
84  X[:, 1] .= 1.0 # intercept
85
86  # Fill  $x_1$  and  $x_2$  columns:  $x_1$  repeats deterministic pattern,  $x_2$  draws fresh
    ↪  $N(0,1)$  each rep
87  @inbounds for rep in 1:m
88      idx_start = (rep - 1) * 20 + 1
89      idx_end = rep * 20
90      X[idx_start:idx_end, 2] .= X1_BASE
91      rand!(rng, Normal(0, 1), view(X, idx_start:idx_end, 3))
92  end
93
94  # Generate y based on design
95   $\beta_0$ ,  $\beta_1$ ,  $\beta_2$  = Float64.(beta)
96
97  @inbounds for i in 1:n
98      x1i = X[i, 2]
99      x2i = X[i, 3]
100
101      # Compute  $v$  (variance scaling)
102      if design == 0
103          v = 1.0
104      else # design == 1 or 2
105          v = exp(0.25 * x1i + 0.25 * x2i)
106      end
107
108      # Generate error term u
109      if design == 2
110          #  $t_5$  distribution (non-normal)
111          u = rand(rng, TDist(5))
112      else # design == 0 or 1
113          # Standard normal
114          u = randn(rng)
115      end
116

```

```

117         # Compute y
118         y[i] =  $\beta_0$  +  $\beta_1$  * x1i +  $\beta_2$  * x2i + sqrt(v) * u
119     end
120
121     return X, y
122 end
123
124 """
125     draw_sample!(X, y, n, design;
126                 beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
127                 rng::AbstractRNG = Random.default_rng())
128
129 In-place version of 'draw_sample'. Mutates pre-allocated arrays 'X' and 'y'.
130 More memory-efficient for Monte Carlo simulations with repeated sampling.
131
132 # Arguments
133 - 'X::AbstractMatrix{Float64}': pre-allocated design matrix ( $n \times 3$ ).
134 - 'y::AbstractVector{Float64}': pre-allocated dependent variable array (length n).
135 - 'n::Integer': sample size, must be a multiple of 20.
136 - 'design::Integer': design number (0, 1, or 2).
137
138 # Keyword arguments
139 - 'beta::AbstractVector{<:Real}': coefficient vector [ $\beta_0, \beta_1, \beta_2$ ] (default: [1.0,
140   ↪ 1.0, 1.0]).
141 - 'rng::AbstractRNG': random number generator (default: Random.default_rng()).
142 """
143 function draw_sample!(
144     X::AbstractMatrix{Float64},
145     y::AbstractVector{Float64},
146     n::Integer,
147     design::Integer;
148     beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
149     rng::AbstractRNG = Random.default_rng(),
150 )
151     # Validate inputs
152     @assert n % 20 == 0 "Sample size n must be a multiple of 20"
153     @assert design ∈ (0, 1, 2) "Design must be 0, 1, or 2"
154     @assert length(beta) == 3 "beta must have 3 elements: [ $\beta_0, \beta_1, \beta_2$ ]"
155     @assert size(X) == (n, 3) "X must be  $n \times 3$ "
156     @assert length(y) == n "y must have length n"
157
158     n = Int(n)
159     m = div(n, 20) # number of repetitions
160
161     # Fill design matrix
162     X[:, 1] .= 1.0 # intercept

```

```

163  # Fill  $x_1$  and  $x_2$  columns:  $x_1$  repeats deterministic pattern,  $x_2$  draws fresh
    ↪  $N(0,1)$  each rep
164  @inbounds for rep in 1:m
165      idx_start = (rep - 1) * 20 + 1
166      idx_end = rep * 20
167      X[idx_start:idx_end, 2] .= X1_BASE
168      rand!(rng, Normal(0, 1), view(X, idx_start:idx_end, 3))
169  end
170
171  # Generate  $y$  based on design
172   $\beta_0, \beta_1, \beta_2 = \text{Float64}.$ (beta)
173
174  @inbounds for i in 1:n
175      x1i = X[i, 2]
176      x2i = X[i, 3]
177
178      # Compute  $v$  (variance scaling)
179      if design == 0
180           $v = 1.0$ 
181      else # design == 1 or 2
182           $v = \exp(0.25 * x1i + 0.25 * x2i)$ 
183      end
184
185      # Generate error term  $u$ 
186      if design == 2
187          #  $t_5$  distribution (non-normal)
188           $u = \text{rand}(rng, \text{TDist}(5))$ 
189      else # design == 0 or 1
190          # Standard normal
191           $u = \text{randn}(rng)$ 
192      end
193
194      # Compute  $y$ 
195       $y[i] = \beta_0 + \beta_1 * x1i + \beta_2 * x2i + \text{sqrt}(v) * u$ 
196  end
197
198  return nothing
199 end
200
201
202 # === OLS ESTIMATION ===
203
204 """
205     ols_fit_k3(X, y)
206
207 Fit OLS regression  $y = X\beta + u$  using StaticArrays (stack-allocated) for  $k=3$ .
208 Computes  $X'X$  and  $X'y$  via scalar accumulation, then

```

```

209 stores in stack-allocated SMatrix/SVector for zero heap allocations.
210
211 # Arguments
212 - 'X::AbstractMatrix{<:Real}': design matrix ( $n \times 3$ ), including intercept column.
213 - 'y::AbstractVector{<:Real}': dependent variable (length  $n$ ).
214
215 # Returns
216 - ' $\beta$ ::Vector{Float64}': OLS coefficient estimates (length 3).
217 - ' $\hat{\epsilon}$ ::Vector{Float64}': OLS residuals (length  $n$ ).
218 """
219 function ols_fit_k3(X::AbstractMatrix{<:Real}, y::AbstractVector{<:Real})
220     n = length(y)
221     @assert size(X, 1) == n
222     @assert size(X, 2) == 3 "ols_fit_k3 optimized for k=3 (intercept + 2
        ↪ regressors)"
223
224     # Compute X'X and X'y via scalar accumulation (no intermediate allocations)
225     # X'X is symmetric, so we only compute upper triangle
226     S11 = 0.0; S12 = 0.0; S13 = 0.0
227     S22 = 0.0; S23 = 0.0; S33 = 0.0
228     Sy1 = 0.0; Sy2 = 0.0; Sy3 = 0.0
229
230     @inbounds for i in 1:n
231         x1 = Float64(X[i, 1])
232         x2 = Float64(X[i, 2])
233         x3 = Float64(X[i, 3])
234         yi = Float64(y[i])
235
236         # Accumulate X'X (symmetric)
237         S11 += x1 * x1
238         S12 += x1 * x2
239         S13 += x1 * x3
240         S22 += x2 * x2
241         S23 += x2 * x3
242         S33 += x3 * x3
243
244         # Accumulate X'y
245         Sy1 += x1 * yi
246         Sy2 += x2 * yi
247         Sy3 += x3 * yi
248     end
249
250     # Build STACK-ALLOCATED 3x3 matrix using SMatrix
251     XtX = @SMatrix [S11 S12 S13;
252                    S12 S22 S23;
253                    S13 S23 S33]
254

```

```

255     Xty = @SVector [Sy1, Sy2, Sy3]
256
257     # Solve via Cholesky factorization (StaticArrays has optimized linear algebra)
258     C = cholesky(XtX)
259      $\hat{\beta}$ _static = C \ Xty
260
261     # Convert back to regular Vector for consistency
262      $\hat{\beta}$  = Vector{Float64}( $\hat{\beta}$ _static)
263
264     # Compute residuals manually (must allocate this since n varies)
265      $\hat{e}$  = Vector{Float64}(undef, n)
266     @inbounds for i in 1:n
267          $\hat{e}[i]$  = Float64(y[i]) - ( $\hat{\beta}[1]$  * Float64(X[i, 1]) +
268                                 $\hat{\beta}[2]$  * Float64(X[i, 2]) +
269                                 $\hat{\beta}[3]$  * Float64(X[i, 3]))
270     end
271
272     return  $\hat{\beta}$ ,  $\hat{e}$ 
273 end
274
275 """
276     ols_fit_k6(X, y)
277
278 Optimized OLS for k=6 regressors using StaticArrays (stack-allocated).
279
280 This is specifically designed for White test auxiliary regression:
281      $\hat{e}^2 \sim 1 + x_1 + x_2 + x_1^2 + x_2^2 + x_1 \cdot x_2$ 
282
283 Uses scalar accumulation to build X'X and X'y, then stores them in
284 stack-allocated SMatrix/SVector for zero heap allocations.
285
286 # Arguments
287 - 'X::AbstractMatrix{<:Real}': design matrix (n × 6).
288 - 'y::AbstractVector{<:Real}': dependent variable (length n).
289
290 # Returns
291 - ' $\hat{\beta}$ ::Vector{Float64}': OLS coefficient estimates (length 6).
292 - ' $\hat{e}$ ::Vector{Float64}': OLS residuals (length n).
293 """
294 function ols_fit_k6(X::AbstractMatrix{<:Real}, y::AbstractVector{<:Real})
295     n = length(y)
296     @assert size(X, 1) == n
297     @assert size(X, 2) == 6 "ols_fit_k6 optimized for k=6 (auxiliary regression)"
298
299     # Compute X'X and X'y via scalar accumulation
300     # X'X is symmetric 6x6, so we compute 21 unique elements
301     S11 = 0.0; S12 = 0.0; S13 = 0.0; S14 = 0.0; S15 = 0.0; S16 = 0.0

```

```

302         S22 = 0.0; S23 = 0.0; S24 = 0.0; S25 = 0.0; S26 = 0.0
303         S33 = 0.0; S34 = 0.0; S35 = 0.0; S36 = 0.0
304         S44 = 0.0; S45 = 0.0; S46 = 0.0
305         S55 = 0.0; S56 = 0.0
306         S66 = 0.0
307
308     Sy1 = 0.0; Sy2 = 0.0; Sy3 = 0.0; Sy4 = 0.0; Sy5 = 0.0; Sy6 = 0.0
309
310     @inbounds for i in 1:n
311         x1 = Float64(X[i, 1])
312         x2 = Float64(X[i, 2])
313         x3 = Float64(X[i, 3])
314         x4 = Float64(X[i, 4])
315         x5 = Float64(X[i, 5])
316         x6 = Float64(X[i, 6])
317         yi = Float64(y[i])
318
319         # Accumulate X'X (upper triangle only)
320         S11 += x1 * x1; S12 += x1 * x2; S13 += x1 * x3; S14 += x1 * x4; S15 += x1 *
        ↪ x5; S16 += x1 * x6
321         S22 += x2 * x2; S23 += x2 * x3; S24 += x2 * x4; S25 += x2 *
        ↪ x5; S26 += x2 * x6
322         S33 += x3 * x3; S34 += x3 * x4; S35 += x3 *
        ↪ x5; S36 += x3 * x6
323         S44 += x4 * x4; S45 += x4 *
        ↪ x5; S46 += x4 * x6
324         S55 += x5 *
        ↪ x5; S56
        ↪ += x5 *
        ↪ x6
325
        ↪ S66
        ↪ +=
        ↪ x6
        ↪ *
        ↪ x6
326
327         # Accumulate X'y
328         Sy1 += x1 * yi
329         Sy2 += x2 * yi
330         Sy3 += x3 * yi
331         Sy4 += x4 * yi
332         Sy5 += x5 * yi
333         Sy6 += x6 * yi
334     end
335
336     # Build STACK-ALLOCATED 6x6 matrix using SMatrix (zero heap allocations!)

```

```

337     XtX = @SMatrix [S11 S12 S13 S14 S15 S16;
338                   S12 S22 S23 S24 S25 S26;
339                   S13 S23 S33 S34 S35 S36;
340                   S14 S24 S34 S44 S45 S46;
341                   S15 S25 S35 S45 S55 S56;
342                   S16 S26 S36 S46 S56 S66]
343
344     Xty = @SVector [Sy1, Sy2, Sy3, Sy4, Sy5, Sy6]
345
346     # Solve using Cholesky (StaticArrays has optimized linear algebra)
347     C = cholesky(XtX)
348      $\hat{\beta}$ _static = C \ Xty
349
350     # Convert back to regular Vector for consistency
351      $\hat{\beta}$  = Vector{Float64}( $\hat{\beta}$ _static)
352
353     # Compute residuals manually
354      $\hat{e}$  = Vector{Float64}(undef, n)
355     @inbounds for i in 1:n
356          $\hat{e}[i]$  = Float64(y[i]) - ( $\hat{\beta}[1]$  * Float64(X[i, 1]) +
357                                 $\hat{\beta}[2]$  * Float64(X[i, 2]) +
358                                 $\hat{\beta}[3]$  * Float64(X[i, 3]) +
359                                 $\hat{\beta}[4]$  * Float64(X[i, 4]) +
360                                 $\hat{\beta}[5]$  * Float64(X[i, 5]) +
361                                 $\hat{\beta}[6]$  * Float64(X[i, 6]))
362     end
363
364     return  $\hat{\beta}$ ,  $\hat{e}$ 
365 end
366
367
368 # === WHITE'S HETEROSKEDASTICITY TEST ===
369
370 """
371     white_test(X, y;  $\alpha=0.05$ )
372 Perform White's test for heteroskedasticity.
373
374 Tests  $H_0$ : Homoskedasticity vs  $H_1$ : Heteroskedasticity.
375
376 # Procedure:
377 1. Fit OLS:  $y = X\beta + u$ , obtain residuals  $\hat{e}$ 
378 2. Construct auxiliary regressors  $Z = [1, x_1, x_2, x_1^2, x_2^2, x_1x_2]$ 
379 3. Fit auxiliary regression:  $\hat{e}^2 = Z\gamma + v$ 
380 4. Compute test statistic:  $W = n \cdot R^2_{aux}$ 
381 5. Compare to  $\chi^2(p)$  where  $p$  = number of slope coefficients in auxiliary regression
382
383 # Arguments

```

```

384 - 'X::AbstractMatrix{<:Real}': design matrix ( $n \times 3$ ), with intercept column.
385 - 'y::AbstractVector{<:Real}': dependent variable (length  $n$ ).
386
387 # Keyword arguments
388 - ' $\alpha$ ::Real': significance level for test (default: 0.05).
389
390 # Returns
391 - 'LM::Float64': test statistic ( $n \cdot R^2$ ).
392 - 'pval::Float64': p-value from  $\chi^2$  distribution.
393 - 'reject::Bool': whether to reject  $H_0$  at level  $\alpha$ .
394 """
395 function white_test(
396     X::AbstractMatrix{<:Real},
397     y::AbstractVector{<:Real};
398      $\alpha$ ::Real = 0.05,
399 )
400     n = length(y)
401     @assert size(X, 1) == n
402     @assert size(X, 2) == 3 "X must have 3 columns: [1,  $x_1$ ,  $x_2$ ]"
403
404     # Step 1: Fit main regression
405      $\hat{\beta}$ ,  $\hat{e}$  = ols_fit_k3(X, y)
406      $\hat{e}^2$  =  $\hat{e}.^2$ 
407
408     # Step 2: Construct auxiliary design matrix Z
409     # Z = [1,  $x_1$ ,  $x_2$ ,  $x_1^2$ ,  $x_2^2$ ,  $x_1 \cdot x_2$ ]
410     x1 = X[:, 2]
411     x2 = X[:, 3]
412
413     Z = Matrix{Float64}(undef, n, 6)
414     Z[:, 1] .= 1.0          # intercept
415     Z[:, 2] .= x1           #  $x_1$ 
416     Z[:, 3] .= x2           #  $x_2$ 
417     Z[:, 4] .= x1.^2        #  $x_1^2$ 
418     Z[:, 5] .= x2.^2        #  $x_2^2$ 
419     Z[:, 6] .= x1 .* x2     #  $x_1 \cdot x_2$ 
420
421     # Step 3: Fit auxiliary regression on  $\hat{e}^2$  (use optimized k=6 solver)
422      $\hat{y}$ ,  $\hat{v}$  = ols_fit_k6(Z,  $\hat{e}^2$ )
423
424     # Step 4: Compute  $R^2$  from auxiliary regression
425      $\hat{e}^2_{\text{fitted}}$  = Z *  $\hat{y}$ 
426     SSR = sum( $\hat{v}.^2$ )
427     SST = sum(( $\hat{e}^2$  .- mean( $\hat{e}^2$ )).^2)
428      $R^2$  = 1.0 - SSR / SST
429
430     # Step 5: Compute test statistic

```

```

431     LM = Float64(n) * R2
432
433     # Degrees of freedom: number of slope coefficients in Z (exclude intercept)
434     df = 5
435
436     # Compute p-value from  $\chi^2$  distribution
437     chisq_dist = Chisq(df)
438     pval = 1.0 - cdf(chisq_dist, LM)
439
440     # Rejection decision
441     reject = pval <  $\alpha$ 
442
443     return LM, pval, reject
444 end
445
446
447 """
448     white_test!(X, y, Z,  $\hat{e}^2$ , aux;  $\alpha=0.05$ )
449
450 Perform White's test for heteroskedasticity using preallocated buffers.
451
452 This version reuses memory buffers across multiple calls, eliminating allocations
453 in Monte Carlo loops. Algorithm and results are identical to 'white_test'.
454
455 Tests  $H_0$ : Homoskedasticity vs  $H_1$ : Heteroskedasticity.
456
457 # Procedure:
458 1. Fit OLS:  $y = X\beta + u$ , obtain residuals  $\hat{e}$ 
459 2. Construct auxiliary regressors  $Z = [1, x_1, x_2, x_1^2, x_2^2, x_1x_2]$  (in-place)
460 3. Fit auxiliary regression:  $\hat{e}^2 = Z\gamma + v$ 
461 4. Compute test statistic:  $W = n \cdot R^2_{\text{aux}}$ 
462 5. Compare to  $\chi^2(p)$  where  $p$  = number of slope coefficients in auxiliary regression
463
464 # Arguments
465 - 'X::AbstractMatrix{<:Real}': design matrix ( $n \times 3$ ), with intercept column.
466 - 'y::AbstractVector{<:Real}': dependent variable (length  $n$ ).
467 - 'Z::AbstractMatrix{Float64}': preallocated buffer for auxiliary design ( $n \times 6$ ).
468 - ' $\hat{e}^2$ ::AbstractVector{Float64}': preallocated buffer for squared residuals ( $n$ ).
469 - 'aux::AbstractVector{Float64}': preallocated buffer for auxiliary calculations
    ↪ ( $n$ ).
470
471 # Keyword arguments
472 - ' $\alpha$ ::Real': significance level for test (default: 0.05).
473
474 # Returns
475 - 'LM::Float64': test statistic ( $n \cdot R^2$ ).
476 - 'pval::Float64': p-value from  $\chi^2$  distribution.

```

```

477 - `reject::Bool`: whether to reject  $H_0$  at level  $\alpha$ .
478 """
479 function white_test!(
480     X::AbstractMatrix{<:Real},
481     y::AbstractVector{<:Real},
482     Z::AbstractMatrix{Float64},
483      $\hat{\epsilon}^2$ ::AbstractVector{Float64},
484     aux::AbstractVector{Float64};
485      $\alpha$ ::Real = 0.05,
486 )
487     n = length(y)
488     @assert size(X, 1) == n
489     @assert size(X, 2) == 3 "X must have 3 columns: [1,  $x_1$ ,  $x_2$ ]"
490     @assert size(Z) == (n, 6) "Z must be  $n \times 6$ "
491     @assert length( $\hat{\epsilon}^2$ ) == n " $\hat{\epsilon}^2$  must have length  $n$ "
492     @assert length(aux) == n "aux must have length  $n$ "
493
494     # Step 1: Fit main regression
495      $\hat{\beta}$ ,  $\hat{\epsilon}$  = ols_fit_k3(X, y)
496
497     # Step 2: Compute squared residuals (in-place)
498     @inbounds for i in 1:n
499          $\hat{\epsilon}^2[i]$  =  $\hat{\epsilon}[i]^2$ 
500     end
501
502     # Step 3: Construct auxiliary design matrix Z (in-place)
503     #  $Z = [1, x_1, x_2, x_1^2, x_2^2, x_1 \cdot x_2]$ 
504     @inbounds for i in 1:n
505          $x_1$  = X[i, 2]
506          $x_2$  = X[i, 3]
507         Z[i, 1] = 1.0
508         Z[i, 2] =  $x_1$ 
509         Z[i, 3] =  $x_2$ 
510         Z[i, 4] =  $x_1 * x_1$ 
511         Z[i, 5] =  $x_2 * x_2$ 
512         Z[i, 6] =  $x_1 * x_2$ 
513     end
514
515     # Step 4: Fit auxiliary regression on  $\hat{\epsilon}^2$ 
516      $\hat{\gamma}$ ,  $\hat{v}$  = ols_fit_k6(Z,  $\hat{\epsilon}^2$ )
517
518     # Step 5: Compute  $R^2$  from auxiliary regression
519     # Compute fitted values using aux buffer
520     @inbounds for i in 1:n
521         aux[i] = ( $\hat{\gamma}[1] * Z[i, 1] + \hat{\gamma}[2] * Z[i, 2] + \hat{\gamma}[3] * Z[i, 3] +$ 
522              $\hat{\gamma}[4] * Z[i, 4] + \hat{\gamma}[5] * Z[i, 5] + \hat{\gamma}[6] * Z[i, 6]$ )
523     end

```

```

524
525     SSR = sum( $\hat{v}^2$ )
526     SST = sum(( $\hat{e}^2$  .- mean( $\hat{e}^2$ )).^2)
527     R2 = 1.0 - SSR / SST
528
529     # Step 6: Compute test statistic
530     LM = Float64(n) * R2
531
532     # Degrees of freedom: number of slope coefficients in Z (exclude intercept)
533     df = 5
534
535     # Compute p-value from  $\chi^2$  distribution
536     chisq_dist = Chisq(df)
537     pval = 1.0 - cdf(chisq_dist, LM)
538
539     # Rejection decision
540     reject = pval <  $\alpha$ 
541
542     return LM, pval, reject
543 end
544
545
546 # === MONTE CARLO SIMULATIONS ===
547
548 """
549     run_exper(n, design, B;
550                $\beta$ =[1.0, 1.0, 1.0],
551                $\alpha$ _levels=(0.01, 0.05, 0.10),
552               rng=Random.default_rng())
553
554 Run B Monte Carlo simulations of White's heteroskedasticity test.
555
556 For each simulation:
557 1. Generate data from model with specified design
558 2. Fit OLS and perform White test
559 3. Record test statistic W, p-value, and rejection decisions
560
561 # Arguments
562 - 'n::Integer': sample size (must be multiple of 20).
563 - 'design::Integer': design number (0, 1, or 2).
564 - 'B::Integer': number of Monte Carlo replications (default: 5000).
565
566 # Keyword arguments
567 - ' $\beta$ ::AbstractVector{<:Real}': true coefficient vector (default: [1.0, 1.0, 1.0]).
568 - ' $\alpha$ _levels::NTuple{N,<:Real}': significance levels for rejection rate calculation.
569 - 'rng::AbstractRNG': random number generator.
570

```

```

571 # Returns
572 - 'NamedTuple': contains  $n$ , design,  $B$ , LM (test statistics), pvals, and rejection
    ↪ indicators.
573
574 # Notes
575 - Design 0 (homoskedastic) measures test SIZE (type I error rate)
576 - Designs 1, 2 (heteroskedastic) measure test POWER
577 """
578 function run_exper(
579     n::Integer,
580     design::Integer,
581     B::Integer=5000;
582      $\beta$ ::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
583      $\alpha$ _levels::NTuple{N,<:Real} = (0.01, 0.05, 0.10),
584     rng::AbstractRNG = Random.default_rng(),
585 ) where N
586     # Preallocate output vectors
587     LM_vec = Vector{Float64}(undef, B)
588     pval_vec = Vector{Float64}(undef, B)
589     reject_mat = Matrix{Bool}(undef, B, N) #  $B \times N$  matrix for  $N$  significance
    ↪ levels
590
591     # Preallocate sample arrays (reused across iterations)
592     X = Matrix{Float64}(undef, n, 3)
593     y = Vector{Float64}(undef, n)
594
595     # Preallocate white_test! buffers (reused across iterations)
596     Z = Matrix{Float64}(undef, n, 6)
597      $\hat{e}^2$  = Vector{Float64}(undef, n)
598     aux = Vector{Float64}(undef, n)
599
600     @inbounds for b in 1:B
601         # Generate sample
602         draw_sample!(X, y, n, design; beta= $\beta$ , rng=rng)
603
604         # Perform White test
605         LM, pval, _ = white_test!(X, y, Z,  $\hat{e}^2$ , aux;  $\alpha$ = $\alpha$ _levels[1])
606
607         # Store results
608         LM_vec[b] = LM
609         pval_vec[b] = pval
610
611         # Compute rejection decisions at all  $\alpha$  levels
612         for (i,  $\alpha$ ) in enumerate( $\alpha$ _levels)
613             reject_mat[b, i] = pval <  $\alpha$ 
614         end
615     end

```

```

616
617     return (
618         n = Int(n),
619         design = Int(design),
620         B = Int(B),
621          $\beta$  = Float64( $\beta$ ),
622          $\alpha$ _levels =  $\alpha$ _levels,
623         LM = LM_vec,
624         pvals = pval_vec,
625         rejections = reject_mat,
626     )
627 end
628
629 """
630     plot_LM_kde(LM_vec, n, design; outdir=..., shade=true, alpha=0.05)
631
632 Plot kernel density estimate of LM statistics with  $\chi^2(5)$  density overlay.
633
634 Uses non-parametric KDE to show smooth empirical density. Under  $H_0$ , the LM
    ↪ statistic
635 should follow  $\chi^2(5)$  asymptotically. As  $n$  increases, the empirical density should
636 converge to the chi-squared distribution.
637
638 # Arguments
639 - 'LM_vec::AbstractVector{<:Real}': vector of LM statistics from simulations.
640 - 'n::Integer': sample size.
641 - 'design::Integer': design number (0, 1, or 2).
642
643 # Keyword arguments
644 - 'outdir::String': output directory for plot (default:
    ↪ script_dir/./out/plots/ej2).
645 - 'shade::Bool': whether to shade rejection region (default: true).
646 - 'alpha::Real': significance level for test (default: 0.05).
647 - 'null::Bool': whether null hypothesis is true (default: true). If false,
    ↪ auto-scales axes to KDE.
648 """
649 function plot_LM_kde(LM_vec::AbstractVector{<:Real}, n::Integer, design::Integer;
650                     outdir::String=joinpath(@__DIR__, "../out/plots/ej2"),
651                     shade::Bool=true,
652                     alpha::Real=0.05,
653                     null::Bool=true)
654     mkpath(outdir)
655
656     # Degrees of freedom for White test
657     df = 5
658
659     # Compute kernel density estimate (non-parametric, smooth empirical density)

```

```

660     kde_result = kde(LM_vec)
661
662     # Determine axis ranges based on whether null hypothesis is true
663     if null
664         # Fixed axis ranges for visual comparison across different n (under H0)
665         xlims_range = (0.0, 25.0)
666         ylims_range = (0.0, 0.2)
667     else
668         # Automatic ranges based on KDE support (when H0 is false)
669         xlims_range = (minimum(kde_result.x), maximum(kde_result.x))
670         ylims_range = (0.0, maximum(kde_result.density) * 1.1)
671     end
672
673     elements = Any[]
674
675     # Pre-compute rejection rate; shade rejection region if requested
676     rejection_title = ""
677     if shade
678         # Critical value for right-tailed test at level alpha ( $\chi^2(5)$  critical
679         ↪ value)
680         chi_crit = quantile(Chisq(df), 1 - alpha)
681         rejection_rate = mean(LM_vec .> chi_crit)
682         rejection_title = @sprintf("Rechazo: %.1f\\%%", rejection_rate * 100)
683
684         # Right tail: manually close polygon to y=0 so pgfplots fills correctly
685         right_idx = kde_result.x .>= chi_crit
686         if any(right_idx)
687             xs, ys = kde_result.x[right_idx], kde_result.density[right_idx]
688             push!(elements, @pgf PGFPlotsX.Plot(
689                 {fill = "gray!30", fill_opacity = 0.4, draw = "none"},
690                 PGFPlotsX.Coordinates([xs; xs[end]; xs[1]], [ys; 0.0; 0.0])))
691         end
692     end
693
694     # Empirical KDE (solid black)
695     push!(elements, @pgf PGFPlotsX.Plot(
696         {black, solid, line_width = "1.5pt"},
697         PGFPlotsX.Coordinates(collect(kde_result.x), collect(kde_result.density))))
698
699     # Chi-squared(5) overlay (dashed gray, semi-transparent)
700     # When null=false this shows the null distribution for reference
701     x_ref = collect(range(xlims_range[1], xlims_range[2], length=200))
702     chisq_dist = Chisq(df)
703     y_ref = pdf.(chisq_dist, x_ref)
704     push!(elements, @pgf PGFPlotsX.Plot(
705         {color = "gray", dashed, line_width = "1.5pt", opacity = 0.7},
706         PGFPlotsX.Coordinates(x_ref, y_ref)))

```

```

706
707 # Build axis using PGFPlotsX directly for precise dimensional and font control.
708 # width/height set the total figure size including all labels.
709 ax = @pgf PGFPlotsX.Axis(
710     {
711         width = "227pt",
712         height = "188pt",
713         scale_only_axis = false,
714         xmin = xlims_range[1], xmax = xlims_range[2],
715         ymin = ylims_range[1], ymax = ylims_range[2],
716         xlabel = raw"Estadístico  $LM$ ",
717         ylabel = "Densidad",
718         raw"xlabel style={font=\fontsize{10}{12}\selectfont}",
719         raw"ylabel style={font=\fontsize{10}{12}\selectfont}",
720         raw"tick label style={font=\fontsize{8}{9.6}\selectfont}",
721         title = rejection_title,
722         raw"title style={font=\fontsize{10}{12}\selectfont, at={(0,1)},
723             ↪ anchor=south west, xshift=0pt}",
724     },
725     elements...
726 )
727 tp = PGFPlotsX.TikzPicture(ax)
728
729 fname_base = "LM_n$(n)_design$(design)"
730 PGFPlotsX.pgfsave(joinpath(outdir, fname_base * ".tex"), tp;
731     ↪ include_preamble=false)
732 PGFPlotsX.pgfsave(joinpath(outdir, fname_base * ".pdf"), tp)
733 end
734 ""
735 print_white_stats(stats)
736
737 Print White test rejection rate statistics in a readable tabular format.
738 ""
739 function print_white_stats(stats)
740     println("\n" * "="^80)
741     println("WHITE TEST REJECTION RATES")
742     println("="^80)
743     println(@sprintf("%-6s %-10s %-8s %-15s",
744         "n", "Design", "α", "Reject Rate"))
745     println("-" ^ 80)
746
747     for s in stats
748         println(@sprintf("%-6d %-10d %-8.3f %-15.4f",
749             s.n, s.design, s.alpha, s.rejection_rate))
750     end

```

```

751     println("="^80 * "\n")
752 end
753
754 """
755     print_white_summary(rejection_stats::Vector)
756
757 Print summary table of White test results across all experiments.
758 """
759 function print_white_summary(rejection_stats::Vector)
760     # Extract unique values
761     n_values = sort(unique([s.n for s in rejection_stats]))
762     design_values = sort(unique([s.design for s in rejection_stats]))
763
764     # Organize data by n, design, alpha
765     data = Dict()
766     for s in rejection_stats
767         if !haskey(data, s.n)
768             data[s.n] = Dict()
769         end
770         if !haskey(data[s.n], s.design)
771             data[s.n][s.design] = Dict()
772         end
773         data[s.n][s.design][s.alpha] = s.rejection_rate
774     end
775
776     println("\n" * "="^80)
777     println("WHITE TEST SUMMARY (Empirical Rejection Rates at  $\alpha = 5\%$ )")
778     println("="^80)
779     println(@sprintf("%-10s", "n"), " | ", join([@sprintf("Design %-4d", d) for d
780         ↪ in design_values], " | "))
781     println("-"^80)
782
783     for n in n_values
784         row_str = @sprintf("%-10d", n)
785         for design in design_values
786             if haskey(data[n], design) && haskey(data[n][design], 0.05)
787                 rate = data[n][design][0.05]
788                 row_str *= " | " * @sprintf("%-10.4f", rate)
789             else
790                 row_str *= " | " * @sprintf("%-10s", "N/A")
791             end
792         end
793         println(row_str)
794     end
795     println("="^80)
796     println("Note: Design 0 measures SIZE, Designs 1-2 measure POWER")
797     println("="^80)

```

```

797 end
798
799 """
800     write_rejection_rates_latex(rejection_stats;
801                                filename="rejection_rates.tex",
802                                outdir=joinpath(@__DIR__, "../out/tables"))
803
804 Write White test rejection rates to a LaTeX booktabs table with hierarchical column
805 ↪ structure.
806
806 The table organizes results by design (columns) and n values (rows), with each
807 ↪ major
808 column subdivided by significance level (1%, 5%, 10%).
809
809 # Arguments
810 - 'rejection_stats::Vector': Vector of rejection statistics from 'run_monte_carlo'.
811
812 # Keyword arguments
813 - 'filename::String': Output filename (default: "rejection_rates.tex").
814 - 'outdir::String': Output directory (default: script_dir/../out/tables/ej2).
815 """
816 function write_rejection_rates_latex(rejection_stats::Vector;
817                                     filename::String = "rejection_rates.tex",
818                                     outdir::String = joinpath(@__DIR__,
819                                                                ↪ "../out/tables/ej2"))
820
819     mkpath(outdir)
820
821     # Extract unique values and sort
822     n_values = sort(unique([s.n for s in rejection_stats]))
823     design_values = sort(unique([s.design for s in rejection_stats]))
824     α_levels = sort(unique([s.alpha for s in rejection_stats]))
825
826     # Organize data: data[n][design][α] = rejection_rate
827     data = Dict{}{}{}
828     for s in rejection_stats
829         if !haskey(data, s.n)
830             data[s.n] = Dict{}{}
831         end
832         if !haskey(data[s.n], s.design)
833             data[s.n][s.design] = Dict{}{}
834         end
835         data[s.n][s.design][s.alpha] = s.rejection_rate
836     end
837
838     # Format rejection rate as percentage with smart rounding
839     # Strips trailing zeros: 100.00 → 100, 97.50 → 97.5, 97.06 → 97.06
840     function split_decimal_rate(x::Real, include_pct::Bool=true)

```

```

841     pct = x * 100.0
842     str = @sprintf("%.2f", pct)
843     # Strip trailing zeros and decimal point if integer
844     str = replace(str, r"\.?0+$" ⇒ "")
845     # Split at decimal point (if still present)
846     parts = split(str, '.')
847     if length(parts) == 2
848         # Has decimal part - include the dot in the decimal part
849         if include_pct
850             return (parts[1], "." * parts[2] * "\\%")
851         else
852             return (parts[1], "." * parts[2])
853         end
854     else
855         # No decimal point (integer) - empty decimal part
856         if include_pct
857             return (str, "\\%")
858         else
859             return (str, "")
860         end
861     end
862 end
863
864 # Open file and write table
865 open(joinpath(outdir, filename), "w") do io
866     # Each design has 3 significance levels, each split into r@{}l = 6 actual
867     ↪ columns per design
868     println(io, "\\begin{tabular}{c} * "r@{}lr@{}lr@{}l" ^length(design_values)
869     ↪ * {}"
870     println(io, "\\toprule")
871
872     # Top level: Design values (each spans 6 columns)
873     print(io, "")
874     for design in design_values
875         print(io, " & \\multicolumn{6}{c}{Diseño $design}")
876     end
877     println(io, " \\\\")
878
879     # Add cmidrules for top level
880     for (i, _) in enumerate(design_values)
881         col_start = 2 + 6*(i-1)
882         col_end = col_start + 5
883         print(io, "\\cmidrule(lr){$col_start-$col_end} ")
884     end
885     println(io)
886
887     # Second level: significance levels (each spans 2 columns)

```

```

886     print(io, "\$n\$")
887     for _ in design_values
888         print(io, " & \\multicolumn{2}{c}{\$1\\%\$}")
889         print(io, " & \\multicolumn{2}{c}{\$5\\%\$}")
890         print(io, " & \\multicolumn{2}{c}{\$10\\%\$}")
891     end
892     println(io, " \\|\\|\\|")
893
894     println(io, "\\midrule")
895
896     # Data rows
897     for (row_idx, n) in enumerate(n_values)
898         print(io, "\$n")
899         is_first_row = (row_idx == 1)
900
901         for design in design_values
902             for  $\alpha$  in  $\alpha$ _levels
903                 if haskey(data[n], design) && haskey(data[n][design],  $\alpha$ )
904                     rate = data[n][design][ $\alpha$ ]
905                     int_part, dec_part = split_decimal_rate(rate, is_first_row)
906                     print(io, " & \$int_part & \$dec_part")
907                 else
908                     print(io, " & \\multicolumn{2}{c}{--}")
909                 end
910             end
911         end
912         println(io, " \\|\\|\\|")
913     end
914
915     println(io, "\\bottomrule")
916     println(io, "\\end{tabular}")
917 end
918
919 @info "LaTeX table written to $(joinpath(outdir, filename))"
920 end
921
922 """
923     run_monte_carlo(B;
924         n_values=[20, 60, 100, 200, 400, 600],
925         design_values=[0, 1, 2],
926          $\beta$ =[1.0, 1.0, 1.0],
927          $\alpha$ _levels=(0.01, 0.05, 0.10),
928         generate_plots=true,
929         rng=Random.default_rng())
930
931 Run White test Monte Carlo simulations for all combinations of sample sizes and
  ↪ designs.

```

```

932
933 This is the "outer loop" that sweeps all parameter combinations. For each (n,
    ↪ design)
934 combination, calls 'run_exper' to perform B Monte Carlo replications. Optionally
935 generates KDE plots of LM statistics.
936
937 # Arguments
938 - 'B::Integer': Monte Carlo replications per combination.
939
940 # Keyword arguments
941 - 'n_values::Vector{<:Integer}': sample sizes to test.
942 - 'design_values::Vector{<:Integer}': designs to test (0, 1, 2).
943 - 'β::AbstractVector{<:Real}': true coefficient vector.
944 - 'α_levels::NTuple{N,<:Real}': significance levels.
945 - 'generate_plots::Bool': whether to generate LM-statistic KDE plots (default:
    ↪ true).
946 - 'rng::AbstractRNG': random number generator.
947
948 # Returns
949 - 'Vector': Rejection rate statistics as vector of NamedTuples containing (n,
    ↪ design, alpha, rejection_rate).
950 """
951 function run_monte_carlo(
952     B::Integer;
953     n_values::Vector{<:Integer} = [20, 60, 100, 200, 400, 600],
954     design_values::Vector{<:Integer} = [0, 1, 2],
955     β::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
956     α_levels::NTuple{N,<:Real} = (0.01, 0.05, 0.10),
957     generate_plots::Bool = true,
958     rng::AbstractRNG = Random.default_rng(),
959 ) where N
960
961     # Storage for statistics
962     rejection_stats = Vector{@NamedTuple{n::Int, design::Int, alpha::Float64,
    ↪ rejection_rate::Float64}}()
963
964     @info "Starting White Test Monte Carlo with B=$B simulations"
965
966     for n in n_values
967         for design in design_values
968             @info "Running experiment: n=$n, design=$design"
969
970             # Run experiment
971             result = run_exper(n, design, B; β=β, α_levels=α_levels, rng=rng)
972
973             # Compute rejection rates for each alpha
974             for (i, alpha) in enumerate(α_levels)

```

```

975         rejection_rate = mean(result.rejections[:, i])
976
977         push!(rejection_stats, (
978             n = n,
979             design = design,
980             alpha = alpha,
981             rejection_rate = rejection_rate
982         ))
983     end
984
985     # Generate LM-statistic plot (optional)
986     if generate_plots
987         @info "Generating LM-statistic plot for n=$n, design=$design"
988         plot_LM_kde(result.LM, n, design;
989             outdir=joinpath(@__DIR__, "../out/plots/ej2"),
990             null=(design == 0))
991     end
992 end
993 end
994
995 @info "Monte Carlo experiment complete"
996
997 return rejection_stats
998 end
999
1000
1001 # === REJECTION RATE BY SAMPLE SIZE PLOTS ===
1002
1003 """
1004     plot_rejection_rates_by_n(B;
1005                     n_grid=20:20:600,
1006                     design_values=[0, 1, 2],
1007                     alpha_levels=(0.01, 0.05, 0.10),
1008                     outdir=joinpath(@__DIR__, "../out/plots/ej2"))
1009 """
1010 Generate plots showing rejection rates as a function of sample size for White test.
1011
1012 Creates one plot per significance level, with separate lines for each design.
1013 Each plot shows dots at data points connected by lines, plus a horizontal reference
1014 line at the nominal significance level.
1015
1016 # Arguments
1017 - 'B::Integer': Number of Monte Carlo replications per (n, design) combination.
1018
1019 # Keyword arguments
1020 - 'n_grid': Sample sizes to test (default: 20:20:600).
1021 - 'design_values::Vector{<:Integer}': Designs to include (default: [0, 1, 2]).

```

```

1022 - ' $\alpha$ _levels::Tuple': Significance levels for plots (default: (0.01, 0.05, 0.10)).
1023 - 'outdir::String': Output directory for plots.
1024 """
1025 function plot_rejection_rates_by_n(
1026     B::Integer;
1027     n_grid = 20:20:600,
1028     design_values::Vector{<:Integer} = [0, 1, 2],
1029      $\alpha$ _levels::Tuple = (0.01, 0.05, 0.10),
1030     outdir::String = joinpath(@__DIR__, "../out/plots/ej2")
1031 )
1032     # Run Monte Carlo with specified n-grid
1033     @info "Running Monte Carlo for rejection rate plots (n =
        ↪ $(n_grid[1]):$(step(n_grid)):$(n_grid[end]))"
1034     n_vals = collect(n_grid)
1035     mc_stats_plot = run_monte_carlo(
1036         B;
1037         n_values = n_vals,
1038         design_values = design_values,
1039          $\beta$  = [1.0, 1.0, 1.0],
1040          $\alpha$ _levels =  $\alpha$ _levels,
1041         generate_plots = false
1042     )
1043
1044     # Extract rejection rates for a given  $\alpha$  level
1045     function extract_rates_by_design(stats, n_vals,  $\alpha$ _target)
1046         designs = sort(unique([s.design for s in stats]))
1047         rates = Dict{<:Integer, Vector{Float64}}()
1048         for d in designs
1049             rates[d] = Vector{Float64}()
1050             for n in n_vals
1051                 idx = findfirst(s -> s.n == n && s.design == d && s.alpha  $\approx$ 
                    ↪  $\alpha$ _target, stats)
1052                 if idx != nothing
1053                     push!(rates[d], stats[idx].rejection_rate)
1054                 else
1055                     push!(rates[d], NaN)
1056                 end
1057             end
1058         end
1059         return rates
1060     end
1061
1062     # Plot styling - all black with different markers
1063     design_labels = Dict{0 => L"Diseño $0$",
1064         1 => L"Diseño $1$",
1065         2 => L"Diseño $2$"}
1066     design_markers = Dict{0 => :circle, 1 => :dtriangle, 2 => :square}

```

```

1067 # Vertical offsets for labels to avoid overlap with lines
1068 design_label_offsets = Dict{0 ⇒ 0.05, 1 ⇒ 0.10, 2 ⇒ 0.07}
1069
1070 mkpath(outdir)
1071
1072 # Create one plot for each significance level
1073 for α_level in α_levels
1074     @info "Creating rejection rate plot for α = $α_level"
1075
1076     rates_by_design = extract_rates_by_design(mc_stats_plot, n_vals, α_level)
1077
1078     # Create plot without legend
1079     p = plot(
1080         xlabel = L"Tamaño de muestra ($n$)",
1081         ylabel = "Tasa de rechazo",
1082         legend = false,
1083         size = (600, 400),
1084         ylims = (0, 1),
1085         yticks = [0, α_level, 0.25, 0.5, 0.75, 1.0],
1086         grid = true,
1087         framestyle = :box
1088     )
1089
1090     # Plot each design as dots connected by lines
1091     for design in sort(collect(keys(rates_by_design)))
1092         plot!(p, n_vals, rates_by_design[design],
1093             label = "",
1094             color = :black,
1095             marker = design_markers[design],
1096             markersize = 4,
1097             linewidth = 1.5,
1098             linestyle = :solid)
1099     end
1100
1101     # Add text labels near the middle of each line (around 50%)
1102     for design in sort(collect(keys(rates_by_design)))
1103         # Get the rates to determine label position
1104         rates = rates_by_design[design]
1105         # Find position around 50% along the x-axis
1106         label_idx = max(1, round{Int, 0.5 * length(n_vals)})
1107         label_x = n_vals[label_idx]
1108         label_y = rates[label_idx]
1109
1110         # Use design-specific offset to avoid overlap
1111         y_offset = design_label_offsets[design]
1112         annotate!(p, label_x, label_y + y_offset,
1113             text(design_labels[design], 9, :center))

```

```

1114     end
1115
1116     # Save plot with  $\alpha$  in filename
1117      $\alpha\_str$  = replace(string( $\alpha\_level$ ), "."  $\Rightarrow$  "")
1118     fname_base = "rejection_rate_by_n_alpha$( $\alpha\_str$ )"
1119     savefig(p, joinpath(outdir, fname_base * ".tex"))
1120     savefig(p, joinpath(outdir, fname_base * ".pdf"))
1121
1122     @info "Plot saved: $(fname_base).pdf"
1123 end
1124
1125 @info "All rejection rate plots saved to $outdir"
1126 end
1127
1128
1129 # === EXECUTION ===
1130
1131 # Run Monte Carlo with plot generation for LM density plots (Figure
    ↪ ej-2-LM-design0)
1132 mc_stats = run_monte_carlo(
1133     5000;
1134     n_values      = [20, 60, 100, 200, 400, 600],
1135     generate_plots = true,
1136     design_values = [0, 1, 2],
1137      $\beta$            = [1.0, 1.0, 1.0],
1138      $\alpha\_levels$   = (0.01, 0.05, 0.10),
1139 )
1140
1141 print_white_summary(mc_stats)
1142 write_rejection_rates_latex(mc_stats)
1143
1144 # Generate rejection rate by n plots (Figures rejection-rates-by-n-alpha-*)
1145 plot_rejection_rates_by_n(100000)

```

El contenido del archivo ej3.jl es el siguiente.

```

1 # =====
2 # TRABAJO FINAL ECONOMETRIA
3 # Ejercicio 2 (parte II): Estimación robusta de la varianza de OLS
4 #
5 # Autor: Felipe Tappata
6 # Fecha: Febrero 2026
7 # =====
8
9 # Load dependencies
10 using Random, Statistics
11 using LinearAlgebra

```

```

12 using Printf, LaTeXStrings
13 using Distributions
14 using StaticArrays
15 using Plots, KernelDensity
16 import PGFPlotsX
17
18 # Set plotting backend
19 function __init_plots__()
20     pgfplotsx()
21     default(tex_output_standalone=false)
22 end
23 __init_plots__()
24
25 # Set seed
26 const SEED = 8869
27 Random.seed!(SEED)
28
29 # Fixed regression design: 20 values of  $x_1$  (repeated across simulations)
30 const X1_BASE = vcat(-1.1, range(-1.0, 1.0, length=18), 1.1)
31
32
33 # === DATA GENERATION ===
34
35 """
36     draw_sample_e!(X, y, e, v, n, design; beta, rng)
37
38 In-place data generation that extends the model of 'draw_sample!' to additionally
39 record the composite errors and variance scalings needed for sandwich estimation.
40
41 Fills 'X' and 'y' identically to 'draw_sample!', and also fills:
42 - 'e[i] =  $\sqrt{v_i} \cdot u_i$ ' - composite error (what OLS residuals estimate)
43 - 'v[i] =  $v_i$ ' - conditional variance of  $e_i$  given  $x_i$  (diagonal of  $\Omega$ )
44
45 Restricted to designs 1 and 2 (heteroskedastic).
46
47 # Arguments
48 - 'X::AbstractMatrix{Float64}': pre-allocated design matrix ( $n \times 3$ ).
49 - 'y::AbstractVector{Float64}': pre-allocated dependent variable (length  $n$ ).
50 - 'e::AbstractVector{Float64}': pre-allocated composite error buffer (length  $n$ ).
51 - 'v::AbstractVector{Float64}': pre-allocated variance scaling buffer (length  $n$ ).
52 - 'n::Integer': sample size, must be a multiple of 20.
53 - 'design::Integer': design number (1 or 2).
54
55 # Keyword arguments
56 - 'beta::AbstractVector{<:Real}': coefficient vector  $[\beta_0, \beta_1, \beta_2]$  (default:  $[1.0,$ 
     $\hookrightarrow 1.0, 1.0]$ ).
57 - 'rng::AbstractRNG': random number generator.

```

```

58 """
59 function draw_sample_e!(
60     X::AbstractMatrix{Float64},
61     y::AbstractVector{Float64},
62     e::AbstractVector{Float64},
63     v::AbstractVector{Float64},
64     n::Integer,
65     design::Integer;
66     beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
67     rng::AbstractRNG = Random.default_rng(),
68 )
69     @assert n % 20 == 0      "Sample size n must be a multiple of 20"
70     @assert design ∈ (1, 2) "draw_sample_e! supports designs 1 and 2 only"
71     @assert length(beta) == 3 "beta must have 3 elements: [ $\beta_0$ ,  $\beta_1$ ,  $\beta_2$ ]"
72     @assert size(X) == (n, 3) "X must be  $n \times 3$ "
73     @assert length(y) == n    "y must have length n"
74     @assert length(e) == n    "e must have length n"
75     @assert length(v) == n    "v must have length n"
76
77     n = Int(n)
78     m = div(n, 20)
79
80     X[:, 1] .= 1.0
81     @inbounds for rep in 1:m
82         idx_start = (rep - 1) * 20 + 1
83         idx_end   = rep * 20
84         X[idx_start:idx_end, 2] .= X1_BASE
85         rand!(rng, Normal(0, 1), view(X, idx_start:idx_end, 3))
86     end
87
88      $\beta_0$ ,  $\beta_1$ ,  $\beta_2$  = Float64.(beta)
89
90     @inbounds for i in 1:n
91         x1i = X[i, 2]
92         x2i = X[i, 3]
93         vi  = exp(0.25 * x1i + 0.25 * x2i)
94         ui  = design == 2 ? rand(rng, TDist(5)) : randn(rng)
95         ei  = sqrt(vi) * ui
96         v[i] = vi
97         e[i] = ei
98         y[i] =  $\beta_0$  +  $\beta_1$  * x1i +  $\beta_2$  * x2i + ei
99     end
100
101     return nothing
102 end
103
104

```

```

105 # === OLS ESTIMATION ===
106
107 """
108     ols_fit_k3(X, y)
109
110 Fit OLS regression  $y = X\beta + u$  using StaticArrays (stack-allocated) for  $k=3$ .
111 Computes  $X'X$  and  $X'y$  via scalar accumulation, then
112 stores in stack-allocated SMatrix/SVector for zero heap allocations.
113
114 # Arguments
115 - 'X::AbstractMatrix{<:Real}': design matrix ( $n \times 3$ ), including intercept column.
116 - 'y::AbstractVector{<:Real}': dependent variable (length  $n$ ).
117
118 # Returns
119 - ' $\hat{\beta}$ ::Vector{Float64}': OLS coefficient estimates (length 3).
120 - ' $\hat{e}$ ::Vector{Float64}': OLS residuals (length  $n$ ).
121 """
122 function ols_fit_k3(X::AbstractMatrix{<:Real}, y::AbstractVector{<:Real})
123     n = length(y)
124     @assert size(X, 1) == n
125     @assert size(X, 2) == 3 "ols_fit_k3 optimized for  $k=3$  (intercept + 2
        ↪ regressors)"
126
127     # Compute  $X'X$  and  $X'y$  via scalar accumulation (no intermediate allocations)
128     #  $X'X$  is symmetric, so we only compute upper triangle
129     S11 = 0.0; S12 = 0.0; S13 = 0.0
130     S22 = 0.0; S23 = 0.0; S33 = 0.0
131     Sy1 = 0.0; Sy2 = 0.0; Sy3 = 0.0
132
133     @inbounds for i in 1:n
134         x1 = Float64(X[i, 1])
135         x2 = Float64(X[i, 2])
136         x3 = Float64(X[i, 3])
137         yi = Float64(y[i])
138
139         # Accumulate  $X'X$  (symmetric)
140         S11 += x1 * x1
141         S12 += x1 * x2
142         S13 += x1 * x3
143         S22 += x2 * x2
144         S23 += x2 * x3
145         S33 += x3 * x3
146
147         # Accumulate  $X'y$ 
148         Sy1 += x1 * yi
149         Sy2 += x2 * yi
150         Sy3 += x3 * yi

```

```

151     end
152
153     # Build STACK-ALLOCATED 3x3 matrix using SMatrix
154     XtX = @SMatrix [S11 S12 S13;
155                   S12 S22 S23;
156                   S13 S23 S33]
157
158     Xty = @SVector [Sy1, Sy2, Sy3]
159
160     # Solve via Cholesky factorization (StaticArrays has optimized linear algebra)
161     C = cholesky(XtX)
162      $\hat{\beta}$ _static = C \ Xty
163
164     # Convert back to regular Vector for consistency
165      $\hat{\beta}$  = Vector{Float64}( $\hat{\beta}$ _static)
166
167     # Compute residuals manually (must allocate this since n varies)
168      $\hat{e}$  = Vector{Float64}(undef, n)
169     @inbounds for i in 1:n
170          $\hat{e}[i]$  = Float64(y[i]) - ( $\hat{\beta}[1]$  * Float64(X[i, 1]) +
171                                 $\hat{\beta}[2]$  * Float64(X[i, 2]) +
172                                 $\hat{\beta}[3]$  * Float64(X[i, 3]))
173     end
174
175     return  $\hat{\beta}$ ,  $\hat{e}$ 
176 end
177
178
179 # === SANDWICH VARIANCE ESTIMATION ===
180
181 """
182     vcov_diags(X,  $\hat{e}$ , e, v, design)
183
184 Compute the diagonal elements of four variance-covariance estimates for the OLS
185 estimator  $\hat{\beta} = (X'X)^{-1}X'y$  under heteroskedasticity.
186
187 All four share the sandwich form  $V = (X'X)^{-1} \cdot M \cdot (X'X)^{-1}$ , differing only
188 in the meat matrix  $M = X'\Omega X$  for different choices of  $\Omega$ :
189
190 | Estimator |  $\Omega$  diagonal | Description |
191 |-----|-----|-----|
192 | HCO |  $\hat{e}^2_i$  | White (1980);  $\hat{e}$  estimates the composite e |
193 | HC1 |  $[n/(n-k)] \cdot \hat{e}^2_i$  | HCO with degrees-of-freedom correction |
194 | V_ideal |  $e^2_i$  | Infeasible: uses true composite errors |
195 | V_true |  $\text{Var}(e_i|x_i)$  | Oracle: uses true conditional variances |
196
197 HC1 is computed at negligible extra cost by scaling the HCO meat.

```

```

198
199 For V_true, the true conditional variance depends on the error distribution:
200 - Design 1 (Normal):  $\text{Var}(e_i|x_i) = v_i \cdot \text{Var}(N(0,1)) = v_i$ 
201 - Design 2 ( $t_5$ ):  $\text{Var}(e_i|x_i) = v_i \cdot \text{Var}(t_5) = v_i \cdot 5/3$ 
202
203 # Arguments
204 - 'X::AbstractMatrix{<:Real}': design matrix ( $n \times 3$ ).
205 - 'ê::AbstractVector{<:Real}': OLS residuals (length n); each  $\hat{e}_i$  estimates  $e_i =$ 
     $\hookrightarrow \sqrt{v_i} u_i$ .
206 - 'e::AbstractVector{<:Real}': true composite errors  $e_i = \sqrt{v_i} u_i$  (length n).
207 - 'v::AbstractVector{<:Real}': variance scaling factors  $v_i = \exp(0.25 \cdot x_{1i} +$ 
     $\hookrightarrow 0.25 \cdot x_{2i})$  (length n).
208 - 'design::Integer': design number (1 or 2) to determine error distribution
     $\hookrightarrow$  variance.
209
210 # Returns
211 Four 'SVector{3,Float64}': '(d_hc0, d_hc1, d_ideal, d_true)', each holding the
212 three diagonal entries  $\text{Var}(\hat{\beta}_0)$ ,  $\text{Var}(\hat{\beta}_1)$ ,  $\text{Var}(\hat{\beta}_2)$  for that estimator.
213 """
214 function vcov_diags(
215     X::AbstractMatrix{<:Real},
216     ê::AbstractVector{<:Real},
217     e::AbstractVector{<:Real},
218     v::AbstractVector{<:Real},
219     design::Integer,
220 )
221     n = length(ê)
222     k = 3
223     @assert size(X) == (n, k) "X must be  $n \times 3$ "
224     @assert length(e) == n "e must have length n"
225     @assert length(v) == n "v must have length n"
226     @assert design ∈ (1, 2) "design must be 1 or 2"
227
228     # Variance of the standardized error distribution
229     # Design 1 (Normal):  $\text{Var}(u) = 1$ 
230     # Design 2 ( $t_5$ ):  $\text{Var}(u) = 5/(5-2) = 5/3$ 
231      $\sigma^2_u = \text{design} == 1 ? 1.0 : 5.0/3.0$ 
232
233     # --- (X'X): symmetric 3x3, accumulate upper triangle ---
234     XtX_11 = 0.0; XtX_12 = 0.0; XtX_13 = 0.0
235         XtX_22 = 0.0; XtX_23 = 0.0
236             XtX_33 = 0.0
237
238     # --- Three meat matrices: also 3x3 symmetric ---
239     # m0: weight =  $\hat{e}^2_i$  (base for HC0 and HC1)
240     m0_11 = 0.0; m0_12 = 0.0; m0_13 = 0.0
241         m0_22 = 0.0; m0_23 = 0.0

```

```

242             m0_33 = 0.0
243
244     # mi: weight =  $e^2_i$  ( $V_{ideal}$ )
245     mi_11 = 0.0; mi_12 = 0.0; mi_13 = 0.0
246             mi_22 = 0.0; mi_23 = 0.0
247             mi_33 = 0.0
248
249     # mt: weight =  $v_i$  ( $V_{true}$ )
250     mt_11 = 0.0; mt_12 = 0.0; mt_13 = 0.0
251             mt_22 = 0.0; mt_23 = 0.0
252             mt_33 = 0.0
253
254     @inbounds for i in 1:n
255         x1 = X[i, 1]; x2 = X[i, 2]; x3 = X[i, 3]
256         w0 =  $\hat{e}[i]^2$ 
257         wi =  $e[i]^2$ 
258         wt = v[i] *  $\sigma^2_u$  # True variance:  $Var(e_i|x_i) = v_i \cdot Var(u_i)$ 
259
260         XtX_11 += x1*x1; XtX_12 += x1*x2; XtX_13 += x1*x3
261                 XtX_22 += x2*x2; XtX_23 += x2*x3
262                 XtX_33 += x3*x3
263
264         m0_11 += w0*x1*x1; m0_12 += w0*x1*x2; m0_13 += w0*x1*x3
265                 m0_22 += w0*x2*x2; m0_23 += w0*x2*x3
266                 m0_33 += w0*x3*x3
267
268         mi_11 += wi*x1*x1; mi_12 += wi*x1*x2; mi_13 += wi*x1*x3
269                 mi_22 += wi*x2*x2; mi_23 += wi*x2*x3
270                 mi_33 += wi*x3*x3
271
272         mt_11 += wt*x1*x1; mt_12 += wt*x1*x2; mt_13 += wt*x1*x3
273                 mt_22 += wt*x2*x2; mt_23 += wt*x2*x3
274                 mt_33 += wt*x3*x3
275     end
276
277     XtX = @SMatrix [XtX_11 XtX_12 XtX_13;
278                     XtX_12 XtX_22 XtX_23;
279                     XtX_13 XtX_23 XtX_33]
280
281     M_hc0 = @SMatrix [m0_11 m0_12 m0_13;
282                      m0_12 m0_22 m0_23;
283                      m0_13 m0_23 m0_33]
284
285     M_ideal = @SMatrix [mi_11 mi_12 mi_13;
286                        mi_12 mi_22 mi_23;
287                        mi_13 mi_23 mi_33]
288

```

```

289     M_true  = @SMatrix [mt_11 mt_12 mt_13;
290                        mt_12 mt_22 mt_23;
291                        mt_13 mt_23 mt_33]
292
293     # Invert (X'X): StaticArrays computes this analytically for 3x3
294     A = inv(XtX)
295
296     hc1_scale = Float64(n) / Float64(n - k)
297
298     V_hc0  = A * M_hc0  * A
299     V_hc1  = hc1_scale * V_hc0      # scalar × SMatrix, zero extra matrix
        ⇨ multiplies
300     V_ideal = A * M_ideal * A
301     V_true  = A * M_true  * A
302
303     d_hc0  = SVector(V_hc0[1,1], V_hc0[2,2], V_hc0[3,3])
304     d_hc1  = SVector(V_hc1[1,1], V_hc1[2,2], V_hc1[3,3])
305     d_ideal = SVector(V_ideal[1,1], V_ideal[2,2], V_ideal[3,3])
306     d_true  = SVector(V_true[1,1], V_true[2,2], V_true[3,3])
307
308     return d_hc0, d_hc1, d_ideal, d_true
309 end
310
311
312 # === MONTE CARLO ===
313
314 """
315     run_exper(n, design, B; β, rng)
316
317 B Monte Carlo replications to measure finite-sample relative bias in robust
        ⇨ variance
318 estimation for OLS under heteroskedasticity.
319
320 For each replication:
321 1. Draw a sample via 'draw_sample_e!' (fills X, y, true composite errors e, and
        ⇨ variances v).
322 2. Compute OLS estimator  $\hat{\beta}$  and residuals  $\hat{e}$  ( $\hat{e}$  estimates the composite error  $e_i =$ 
        ⇨  $\sqrt{v_i} u_i$ ).
323 3. Compute diagonal entries of HC0, HC1, V_ideal, and V_true via 'vcov_diags'.
324 4. Accumulate relative bias: (estimated - true) / true for each coefficient  $j \in$ 
        ⇨ {0,1,2}.
325
326 # Arguments
327 - 'n::Integer': sample size (multiple of 20).
328 - 'design::Integer': design number (1 or 2).
329 - 'B::Integer': number of Monte Carlo replications (default: 5000).
330

```

```

331 # Keyword arguments
332 - ' $\beta::\text{AbstractVector}\{<:\text{Real}\}$ ': true coefficient vector  $[\beta_0, \beta_1, \beta_2]$  (default:  $[1.0,$ 
     $\hookrightarrow 1.0, 1.0]$ ).
333 - ' $\text{rng}::\text{AbstractRNG}$ ': random number generator.
334
335 # Returns
336 NamedTuple with:
337 - ' $n$ ', ' $\text{design}$ ', ' $B$ ': experiment parameters.
338 - ' $\text{rel\_bias\_hc0}$ ', ' $\text{rel\_bias\_hc1}$ ', ' $\text{rel\_bias\_ideal}$ ': ' $\text{SVector}\{3\}$ ' of relative biases
339  $(b_0, b_1, b_2)$  for each estimator, where  $b_j = \text{average of } (\hat{V}_j - V_j)/V_j \text{ over } B$ 
     $\hookrightarrow \text{replications}$ .
340 - ' $\text{total\_bias\_hc0}$ ', ' $\text{total\_bias\_hc1}$ ', ' $\text{total\_bias\_ideal}$ ':  $|b_0| + |b_1| + |b_2|$  (total
     $\hookrightarrow \text{relative bias}$ ).
341 """
342 function run_exper(
343     n::Integer,
344     design::Integer,
345     B::Integer = 5000;
346      $\beta::\text{AbstractVector}\{<:\text{Real}\} = [1.0, 1.0, 1.0]$ ,
347      $\text{rng}::\text{AbstractRNG} = \text{Random.default\_rng}()$ ,
348 )
349     @assert design  $\in \{1, 2\}$  "run_exper (ej3) requires design  $\in \{1, 2\}$ "
350
351     # Preallocate sample and helper buffers (reused across replications)
352     X = Matrix{Float64}(undef, n, 3)
353     y = Vector{Float64}(undef, n)
354     e = Vector{Float64}(undef, n)
355     v = Vector{Float64}(undef, n)
356
357     # Accumulators: sum over B of  $(\hat{V}_j - V_j)/V_j$  for each estimator and coefficient
358     acc_hc0 = MVector{3, Float64}(0.0, 0.0, 0.0)
359     acc_hc1 = MVector{3, Float64}(0.0, 0.0, 0.0)
360     acc_ideal = MVector{3, Float64}(0.0, 0.0, 0.0)
361
362     @inbounds for b in 1:B
363         draw_sample_e!(X, y, e, v, n, design; beta= $\beta$ , rng=rng)
364          $\hat{e}$  = ols_fit_k3(X, y)
365         d_hc0, d_hc1, d_ideal, d_true = vcov_diags(X,  $\hat{e}$ , e, v, design)
366
367         @inbounds for j in 1:3
368             vt = d_true[j]
369             acc_hc0[j] += (d_hc0[j] - vt) / vt
370             acc_hc1[j] += (d_hc1[j] - vt) / vt
371             acc_ideal[j] += (d_ideal[j] - vt) / vt
372         end
373     end
374

```

```

375   Binv = 1.0 / Float64(B)
376   rb_hc0  = SVector{3}(acc_hc0)  * Binv
377   rb_hc1  = SVector{3}(acc_hc1)  * Binv
378   rb_ideal = SVector{3}(acc_ideal) * Binv
379
380   return (
381       n          = Int(n),
382       design     = Int(design),
383       B          = Int(B),
384       rel_bias_hc0 = rb_hc0,
385       rel_bias_hc1 = rb_hc1,
386       rel_bias_ideal = rb_ideal,
387       total_bias_hc0 = sum(abs, rb_hc0),
388       total_bias_hc1 = sum(abs, rb_hc1),
389       total_bias_ideal = sum(abs, rb_ideal),
390   )
391 end
392
393 """
394   run_monte_carlo(B; n_values, design_values,  $\beta$ , rng)
395
396   Outer loop: run 'run_exper' for all combinations of sample sizes and designs.
397
398   # Arguments
399   - 'B::Integer': Monte Carlo replications per (n, design) combination.
400
401   # Keyword arguments
402   - 'n_values::Vector{<:Integer}': sample sizes (default: [20, 60, 100, 200, 400,
403     ↪ 600]).
404   - 'design_values::Vector{<:Integer}': designs to test (default: [1, 2]).
405   - ' $\beta$ ::AbstractVector{<:Real}': true coefficient vector.
406   - 'rng::AbstractRNG': random number generator.
407
408   # Returns
409   Vector of NamedTuples, one per (n, design) pair, as returned by 'run_exper'.
410   """
411   function run_monte_carlo(
412       B::Integer;
413       n_values::Vector{<:Integer} = [20, 60, 100, 200, 400, 600],
414       design_values::Vector{<:Integer} = [1, 2],
415        $\beta$ ::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
416       rng::AbstractRNG = Random.default_rng(),
417   )
418       results = Vector{Any}()
419
420       @info "Starting variance bias Monte Carlo: B=$B"

```

```

421     for n in n_values
422         for design in design_values
423             @info " n=$n, design=$design"
424             push!(results, run_exper(n, design, B;  $\beta=\beta$ , rng=rng))
425         end
426     end
427
428     @info "Monte Carlo complete"
429     return results
430 end
431
432
433 # === VIEWING RESULTS ===
434
435 """
436     print_varbias_results(mc_results)
437
438     Print relative bias statistics to the terminal in a readable tabular format.
439 """
440 function print_varbias_results(mc_results)
441     println("\n" * "="^90)
442     println("VARIANCE BIAS (relative bias of robust variance estimators)")
443     println("="^90)
444     println(@sprintf("%-6s %-8s %-8s %10s %10s %10s %12s",
445                     "n", "Design", "Est", "b0", "b1", "b2", "||b||1"))
446     println("-"^90)
447
448     for r in mc_results
449         for (label, rb, tb) in [
450             ("HC0", r.rel_bias_hc0, r.total_bias_hc0),
451             ("HC1", r.rel_bias_hc1, r.total_bias_hc1),
452             ("Ideal", r.rel_bias_ideal, r.total_bias_ideal),
453         ]
454             println(@sprintf("%-6d %-8d %-8s %10.4f %10.4f %10.4f %12.4f",
455                             r.n, r.design, label,
456                             rb[1], rb[2], rb[3], tb))
457         end
458     end
459     println("-"^90)
460     println("="^90 * "\n")
461 end
462
463 """
464     write_varbias_latex(mc_results;
465                         estimators=[:ideal, :hc0],
466                         filename="varbias_ideal_hc0.tex",
467                         outdir=joinpath(@__DIR__, "../out/tables/ej2"))

```

```

468
469 Write relative bias results to a booktabs LaTeX table.
470
471 Column structure (three-level hierarchy): Design → Estimator → ( $b_0$ ,  $b_1$ ,  $b_2$ ,  $\|b\|_1$ ).
472 Numbers are decimal-aligned using  $r@{.}l$  column pairs.
473
474 Call once per comparison pair:
475
476     write_varbias_latex(mc_results; estimators=[:hc0, :ideal],
477         ↪ filename="varbias_hc0_ideal.tex")
478
479     write_varbias_latex(mc_results; estimators=[:hc0, :hc1],
480         ↪ filename="varbias_hc0_hc1.tex")
481
482 # Arguments
483 - 'mc_results': vector of NamedTuples from 'run_monte_carlo'.
484
485 # Keyword arguments
486 - 'estimators::Vector{Symbol}': exactly two estimators to compare; valid values
487   are ':ideal', ':hc0', ':hc1'.
488 - 'filename::String': output filename.
489 - 'outdir::String': output directory (default: script_dir/../out/tables/ej2).
490
491 function write_varbias_latex(
492     mc_results;
493     estimators::Vector{Symbol} = [:hc0, :ideal],
494     filename::String           = "varbias_hc0_ideal.tex",
495     outdir::String              = joinpath(@__DIR__, "../out/tables/ej2"),
496 )
497     @assert length(estimators) == 2 "Exactly two estimators must be specified"
498     @assert all(e ∈ (:ideal, :hc0, :hc1) for e in estimators) "Each estimator must
499       ↪ be :ideal, :hc0, or :hc1"
500
501     mkpath(outdir)
502
503     # Access the relative bias SVector and total bias scalar for a given estimator
504     function get_biases(r, est::Symbol)
505         est == :ideal && return (r.rel_bias_ideal, r.total_bias_ideal)
506         est == :hc0   && return (r.rel_bias_hc0,   r.total_bias_hc0)
507         est == :hc1   && return (r.rel_bias_hc1,   r.total_bias_hc1)
508     end
509
510     est_labels = Dict(
511         :ideal ⇒ raw"\widehat{V}^{\mathrm{ideal}}$",
512         :hc0   ⇒ raw"\widehat{V}^{\mathrm{HC0}}$",
513         :hc1   ⇒ raw"\widehat{V}^{\mathrm{HC1}}$",
514     )
515
516

```

```

512 design_values = sort(unique([r.design for r in mc_results]))
513 n_values      = sort(unique([r.n      for r in mc_results]))
514
515 # Build lookup: data[design][n] = NamedTuple
516 data = Dict()
517 for r in mc_results
518     haskey(data, r.design) || (data[r.design] = Dict())
519     data[r.design][r.n] = r
520 end
521
522 # Format a bias value for  $r@{\cdot}l$  decimal alignment.
523 # Wraps negative integer part in math mode for the minus sign.
524 function split_bias(x::Real)
525     str      = @sprintf("%.3f", x)
526     parts    = split(str, '.')
527     int_part = parts[1]
528     dec_part = length(parts) == 2 ? parts[2] : "000"
529     startswith(int_part, "-") && (int_part = "\$" * int_part * "\$")
530     return (int_part, dec_part)
531 end
532
533 # Column layout: one  $r@{\cdot}l$  pair per (stat  $\times$  estimator  $\times$  design)
534 n_stats      = 4 #  $b_0, b_1, b_2, \|b\|_1$ 
535 cols_per_est = n_stats * 2
536 cols_per_design = length(estimators) * cols_per_est
537 col_spec      = "c" * ("r@{\cdot}l" ^ (n_stats * length(estimators))) ^
538     ↪ length(design_values)
539
540 open(joinpath(outdir, filename), "w") do io
541     println(io, "\\begin{tabular}{\$col_spec}")
542     println(io, "\\toprule")
543
544     # Level 1: Design
545     print(io, "")
546     for d in design_values
547         print(io, " & \\multicolumn{$(cols_per_design)}{c}{Dise\\~no \$d}")
548     end
549     println(io, " \\\\"")
550
551     for (i, _) in enumerate(design_values)
552         col_start = 2 + cols_per_design * (i - 1)
553         col_end   = col_start + cols_per_design - 1
554         print(io, "\\cmidrule(lr){$col_start-$col_end} ")
555     end
556     println(io)
557
558     # Level 2: Estimator

```

```

558     print(io, "")
559     for _ in design_values
560         for est in estimators
561             print(io, " &
                    ↪ \\multicolumn{$(cols_per_est)}{c}{$(est_labels[est])}")
562         end
563     end
564     println(io, " \\\\")
565
566     for (i, _) in enumerate(design_values)
567         for (j, _) in enumerate(estimators)
568             col_start = 2 + cols_per_design * (i - 1) + cols_per_est * (j - 1)
569             col_end   = col_start + cols_per_est - 1
570             print(io, "\\cmidrule(lr){$col_start-$col_end} ")
571         end
572     end
573     println(io)
574
575     # Level 3: Statistic headers
576     print(io, "\\$n\\$")
577     for _ in design_values
578         for _ in estimators
579             print(io, " & \\multicolumn{2}{c}{\\$b_0\\$}")
580             print(io, " & \\multicolumn{2}{c}{\\$b_1\\$}")
581             print(io, " & \\multicolumn{2}{c}{\\$b_2\\$}")
582             print(io, " & \\multicolumn{2}{c}{\\$\\|\\|\\boldsymbol{b}\\|\\|_1\\$}")
583         end
584     end
585     println(io, " \\\\")
586
587     println(io, "\\midrule")
588
589     # Data rows
590     for n in n_values
591         print(io, "\\$n")
592         for d in design_values
593             for est in estimators
594                 if haskey(data, d) && haskey(data[d], n)
595                     rb, tb = get_biases(data[d][n], est)
596                     for val in (rb[1], rb[2], rb[3], tb)
597                         int_p, dec_p = split_bias(val)
598                         print(io, " & $int_p & $dec_p")
599                     end
600                 else
601                     for _ in 1:n_stats
602                         print(io, " & \\multicolumn{2}{c}{--}")
603                     end

```

```

604         end
605     end
606 end
607     println(io, " \\\\")
608 end
609
610     println(io, "\\bottomrule")
611     println(io, "\\end{tabular}")
612 end
613
614 @info "LaTeX table written to $(joinpath(outdir, filename))"
615 end
616
617
618 # === PLOTTING ===
619
620 """
621     plot_varbias_by_n(B;
622         n_grid=20:20:600,
623         design=1,
624         metric=:b0,
625         estimators=[:hc0, :hc1, :ideal],
626         beta=[1.0, 1.0, 1.0],
627         outdir=joinpath(@__DIR__, "../out/plots/ej2"))
628
629 Generate plot showing relative bias as a function of sample size.
630
631 Creates one plot showing the specified metric ( $b_0$ ,  $b_1$ ,  $b_2$ , or total bias) for the
632 given design, with separate lines for each estimator specified.
633
634 # Arguments
635 - `B::Integer`: Number of Monte Carlo replications per  $n$ .
636
637 # Keyword arguments
638 - `n_grid`: Sample sizes to test (default: 20:20:600).
639 - `design::Integer`: Design number (1 or 2).
640 - `metric::Symbol`: Which bias metric to plot; one of `:b0`, `:b1`, `:b2`, `:total`
641   ↪ (default: `:b0`).
642 - `estimators::Vector{Symbol}`: Estimators to include; subset of `[:hc0, :hc1,
643   ↪ :ideal]` (default: all three).
644 - `beta::AbstractVector{<:Real}`: True coefficient vector.
645 - `outdir::String`: Output directory for plots.
646 """
647
648 function plot_varbias_by_n(
649     B::Integer;
650     n_grid = 20:20:600,
651     design::Integer = 1,

```

```

649 metric::Symbol = :b0,
650 estimators::Vector{Symbol} = [:hc0, :hc1, :ideal],
651 beta::AbstractVector{<:Real} = [1.0, 1.0, 1.0],
652 outdir::String = joinpath(@__DIR__, "../out/plots/ej2"),
653 )
654 @assert design ∈ (1, 2) "Design must be 1 or 2"
655 @assert metric ∈ (:b0, :b1, :b2, :total) "Metric must be :b0, :b1, :b2, or
    ↪ :total"
656 @assert all(e ∈ (:hc0, :hc1, :ideal) for e in estimators) "Each estimator must
    ↪ be :hc0, :hc1, or :ideal"
657 @assert length(estimators) >= 1 "At least one estimator must be specified"
658
659 # Run Monte Carlo with specified n-grid
660 @info "Running Monte Carlo for varbias plot: design=$design, metric=$metric,
    ↪ n=$(n_grid[1]):$(step(n_grid)):$(n_grid[end])"
661 n_vals = collect(n_grid)
662 mc_res = run_monte_carlo(
663     B;
664     n_values = n_vals,
665     design_values = [design],
666     β = beta,
667 )
668
669 # Extract bias values for the specified metric
670 function get_bias_value(r, est::Symbol, metric::Symbol)
671     rb, tb = if est == :hc0
672         (r.rel_bias_hc0, r.total_bias_hc0)
673     elseif est == :hc1
674         (r.rel_bias_hc1, r.total_bias_hc1)
675     else # :ideal
676         (r.rel_bias_ideal, r.total_bias_ideal)
677     end
678
679     metric == :b0    && return rb[1]
680     metric == :b1    && return rb[2]
681     metric == :b2    && return rb[3]
682     metric == :total && return tb
683 end
684
685 # Build data: bias_data[estimator] = vector of bias values across n_vals
686 bias_data = Dict{Symbol, Vector{Float64}}{ }
687 for est in estimators
688     bias_data[est] = Vector{Float64}()
689     for n in n_vals
690         idx = findfirst(r -> r.n == n && r.design == design, mc_res)
691         push!(bias_data[est], get_bias_value(mc_res[idx], est, metric))
692     end

```

```

693 end
694
695 # Plot styling - monochrome with circles, different line styles
696 est_labels = Dict(
697     :hc0  ⇒ L"\widehat{\mathbf{V}}-\widehat{\beta}^{\mathrm{HC}}_0",
698     :hc1  ⇒ L"\widehat{\mathbf{V}}-\widehat{\beta}^{\mathrm{HC}}_1",
699     :ideal ⇒ L"\widehat{\mathbf{V}}-\widehat{\beta}^{\mathrm{ideal}}",
700 )
701 est_linestyles = Dict(:hc0 ⇒ :dot, :hc1 ⇒ :dash, :ideal ⇒ :solid)
702
703 # Metric label for y-axis
704 metric_labels = Dict(
705     :b0  ⇒ L"$b_0$",
706     :b1  ⇒ L"$b_1$",
707     :b2  ⇒ L"$b_2$",
708     :total ⇒ L"$\\|\\boldsymbol{b}\\|_1$",
709 )
710
711 mkpath(outdir)
712
713 # Legend position: top right for total bias, bottom right otherwise
714 legend_pos = metric == :total ? :topright : :bottomright
715
716 # Create plot
717 p = plot(
718     xlabel = L"Tamaño de muestra ($n$)",
719     ylabel = "Sesgo relativo",
720     legend = legend_pos,
721     size = (600, 400),
722     grid = true,
723     framestyle = :box,
724     guidefontsize = 12,
725     tickfontsize = 10,
726     legendfontsize = 12,
727     background_color_legend = nothing,
728     foreground_color_legend = nothing,
729 )
730
731 # Plot each estimator as dots connected by lines
732 for est in estimators
733     plot!(p, n_vals, bias_data[est],
734         label = est_labels[est],
735         color = :black,
736         marker = :circle,
737         markersize = 1.5,
738         linewidth = 1.5,
739         linestyle = est_linestyles[est])

```

```

740     end
741
742     # Add horizontal line at zero for reference
743     hline!(p, [0.0],
744           linestyle = :dash,
745           color = :gray,
746           alpha = 0.5,
747           linewidth = 1.5,
748           label = "")
749
750     # Save plot
751     metric_str = string(metric)
752     fname_base = "varbias_$(metric_str)_design$(design)"
753     savefig(p, joinpath(outdir, fname_base * ".tex"))
754     savefig(p, joinpath(outdir, fname_base * ".pdf"))
755
756     @info "Plot saved: $(fname_base).pdf"
757 end
758
759
760 # === EXECUTION ===
761
762 mc_results = run_monte_carlo(
763     5000;
764     n_values      = [20, 60, 100, 200, 400, 600],
765     design_values = [1, 2],
766      $\beta$           = [1.0, 1.0, 1.0],
767 )
768
769 print_varbias_results(mc_results)
770
771 write_varbias_latex(mc_results;
772                    estimators = [:hc0, :ideal],
773                    filename   = "varbias_hc0_ideal.tex")
774
775 write_varbias_latex(mc_results;
776                    estimators = [:hc0, :hc1],
777                    filename   = "varbias_hc0_hc1.tex")
778
779 # Generate variance bias plots for all combinations (Figures ej2-varbias-*)
780 for design in [1, 2]
781     for metric in [:b0, :b1, :b2, :total]
782         plot_varbias_by_n(100000; design=design, metric=metric)
783     end
784 end
785

```
