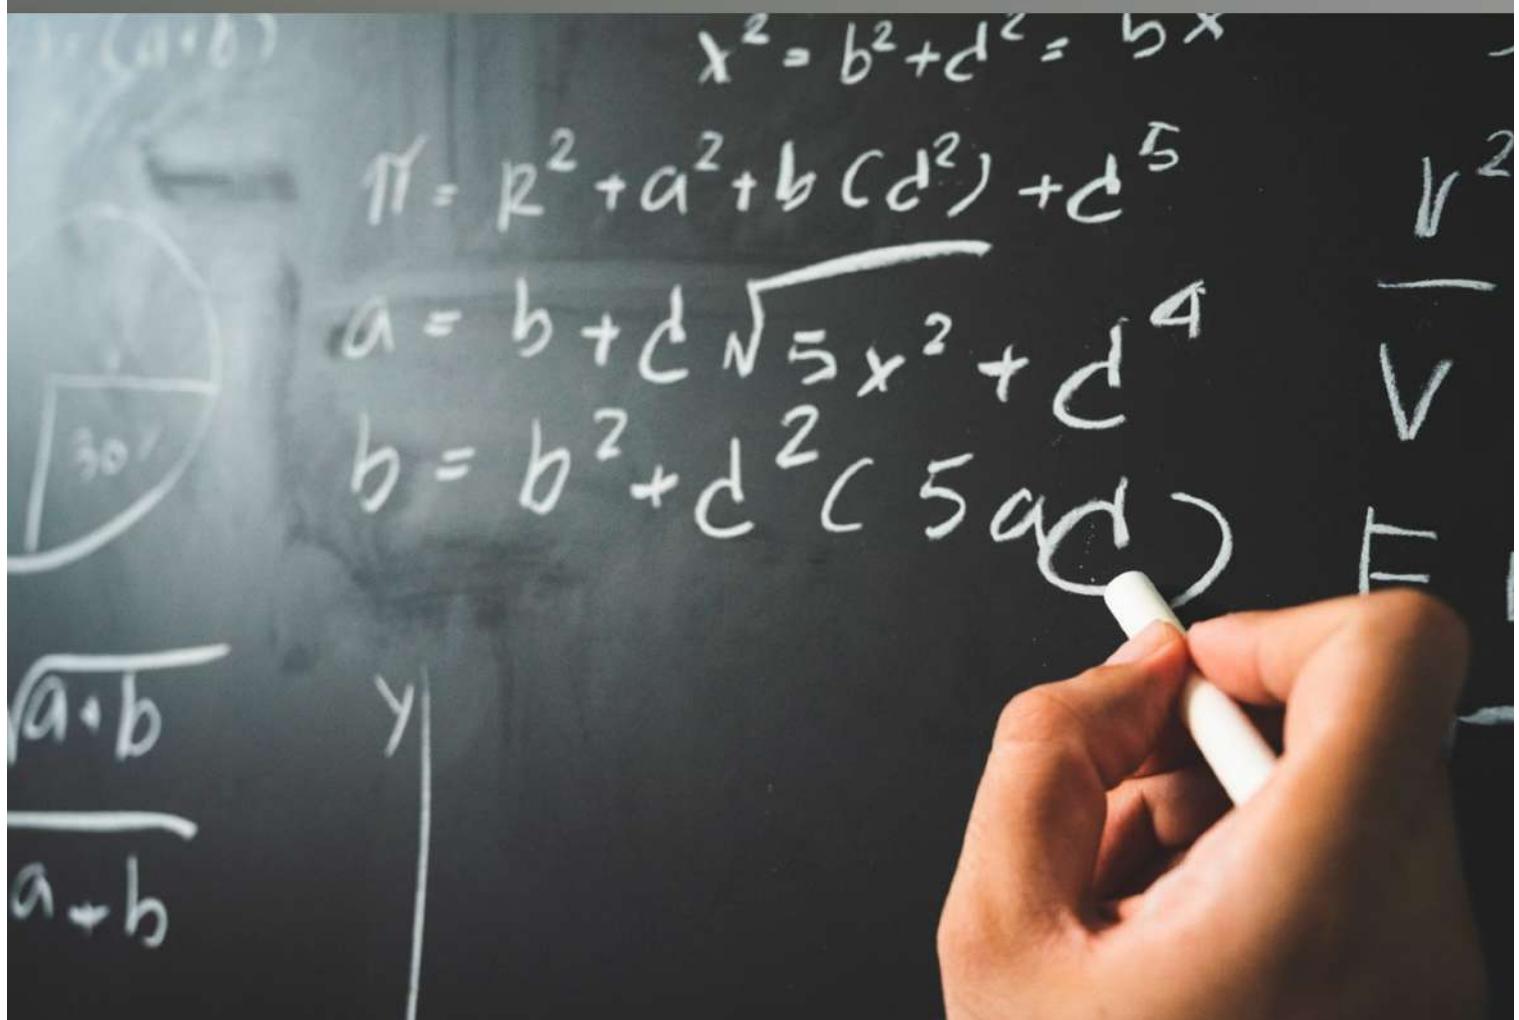




FUNDAMENTOS MATEMÁTICOS DE REGRESIÓN LINEAL

PARTE III

© MOISÉS ARREGUÍN SÁMANO
ANDREA DAMARIS HERNÁNDEZ ALLAUCA
SALVADOR SAMPAYO MALDONADO
PAMELA ROSA TACO HERNÁNDEZ



FUNDAMENTOS MATEMÁTICOS DE REGRESIÓN LINEAL PARTE III

Moisés Arreguín Sámano
Andrea Damaris Hernández Allauca
Salvador Sampayo Maldonado
Pamela Rosa Taco Hernández



© Autores

FUNDAMENTOS MATEMÁTICOS DE REGRESIÓN LINEAL
Parte III

Moisés Arreguín- Sámano, Docente de la Universidad Estatal de Bolívar, Bolívar, Ecuador.

Andrea Damaris Hernández- Allauca, Docente Investigador Escuela Superior Politécnica de Chimborazo- Grupo de Investigación y Transferencia de Tecnologías en Recursos Hídricos (GITRH) y Grupo de Investigación en Turismo (GITUR). Riobamba, Ecuador.

Salvador Sampayo Maldonado, Profesor de la carrera de Biología en la Facultad de Estudios Superiores Iztacala. De la Universidad Nacional Autónoma de México. Tlalnepantla, estado de México.

Pamela Rosa Taco - Hernández, Ingeniera Civil, Maestría en Ingeniería Civil con mención en Gestión de la Construcción (c). Investigadora independiente.



Casa Editora del Polo - CASEDELPO CIA. LTDA.

Departamento de Edición

Editado y distribuido por:

Editorial: Casa Editora del Polo

Sello Editorial: 978-9942-816

Manta, Manabí, Ecuador. 2019

Teléfono: (05) 6051775 / 0991871420

Web: www.casedelpo.com

ISBN: 978-9942-621-66-5

DOI: <https://doi.org/10.23857/978-9942-621-66-5>

© Primera edición

© Enero - 2024

Impreso en Ecuador

Revisión, Ortografía y Redacción:

Lic. Jessica Mero Vélez

Diseño de Portada:

Michael Josué Suárez-Espinar

Diagramación:

Ing. Edwin Alejandro Delgado-Veliz

Director Editorial:

Dra. Tibisay Milene Lamus-García

Todos los libros publicados por la Casa Editora del Polo, son sometidos previamente a un proceso de evaluación realizado por árbitros calificados.

Este es un libro digital y físico, destinado únicamente al uso personal y colectivo en trabajos académicos de investigación, docencia y difusión del Conocimiento, donde se debe brindar crédito de manera adecuada a los autores.

© Reservados todos los derechos. Queda estrictamente prohibida, sin la autorización expresa de los autores, bajo las sanciones establecidas en las leyes, la reproducción parcial o total de este contenido, por cualquier medio o procedimiento, parcial o total de este contenido, por cualquier medio o procedimiento.

Comité Científico Académico

Dr. Lucio Noriero-Escalante

Universidad Autónoma de Chapingo, México

Dra. Yorkanda Masó-Dominico

Instituto Tecnológico de la Construcción, México

Dr. Juan Pedro Machado-Castillo

Universidad de Granma, Bayamo. M.N. Cuba

Dra. Fanny Miriam Sanabria-Boudri

Universidad Nacional Enrique Guzmán y Valle, Perú

Dra. Jennifer Quintero-Medina

Universidad Privada Dr. Rafael Belloso Chacín, Venezuela

Dr. Félix Colina-Ysea

Universidad SISE. Lima, Perú

Dr. Reinaldo Velasco

Universidad Bolivariana de Venezuela, Venezuela

Dra. Lenys Piña-Ferrer

Universidad Rafael Belloso Chacín, Maracaibo, Venezuela

Dr. José Javier Nuvaez-Castillo

Universidad Cooperativa de Colombia, Santa Marta,
Colombia

Constancia de Arbitraje

La Casa Editora del Polo, hace constar que este libro proviene de una investigación realizada por los autores, siendo sometido a un arbitraje bajo el sistema de doble ciego (peer review), de contenido y forma por jurados especialistas. Además, se realizó una revisión del enfoque, paradigma y método investigativo; desde la matriz epistémica asumida por los autores, aplicándose las normas APA, Sexta Edición, proceso de anti plagio en línea Plagiarismo, garantizándose así la científicidad de la obra.

Comité Editorial

Abg. Néstor D. Suárez-Montes
Casa Editora del Polo (CASEDELPO)

Dra. Juana Cecilia-Ojeda
Universidad del Zulia, Maracaibo, Venezuela

Dra. Maritza Berenguer-Gouarnaluses
Universidad Santiago de Cuba, Santiago de Cuba, Cuba

Dr. Víctor Reinaldo Jama-Zambrano
Universidad Laica Eloy Alfaro de Manabí, Ext. Chone

Contenido

PROLOGO.....	15
INTRODUCCIÓN.....	19
CAPÍTULO I	
REGRESIÓN LINEAL MÚLTIPLE.....	23
1.1 Regresión lineal múltiple.....	26
1.1.1 Ejercicios Numéricos.....	27
1.3 Ejercicios Teóricos.....	39
CAPÍTULO II	
INTRODUCCIÓN A MODELOS ECONOMÉTRICOS	47
2.1. Cobb-Douglas.....	49
2.2. Función de consumo.....	51
2.3. Estructura de consumo.....	52
2.4. Curva de Phillips.....	53
CAPÍTULO III	
INTRODUCCIÓN A MODELOS INTRODUCCIÓN A SERIES DE TIEMPO.....	57
3.1. Introducción.....	59
3.2. Componentes.....	60
3.2.1. Tendencia secular (T).....	60
3.2.2. Variación estacional.....	61

3.2.3. Variación cíclica C.....	61	que trabaja R.....	86
3.2.4. Fluctuación irregular I.....	62	4.5. Ejercicios de aplicación.....	88
3.3. Atenuación.....	62	4.5.1. Ejemplo 1. “Arroz.Nacional”	88
3.3.1. Promedios móviles.....	64		
3.3.2. Media móvil doble.....	66	REFERENCIAS BIBLIOGRÁFICAS	283
3.3.3Exponencial.....	67		
3.3.4. Exponencial doble.....	69		
3.3.5. Método de Holt.....	70		
3.3.6. Método de Winters.....	72		
3.4. Comparación de métodos.....	73		
3.5. Ejercicios.....	74		

CAPÍTULO IV
DESARROLLO DE EJERCICIOS MEDIANTE
SOFTWARE R.....79

4. Archivo de comando o script.....	81
4.1. Para instalar un conjunto de comandos con que R crea herramienta para generación de i nformes dinámico en R.....	81
4.2. Para instalar un conjunto de comandos c on que R crea presentaciones en power point, libros, artículos u otros textos.....	83
4.3. Para instalar un conjunto de comandos que permite usar memoria de disco duro en memoria RAM de la PC tal que facilita cálculos y uso óptimo de la computadora en R.....	84
4.4. Para cargar un conjunto de comandos con	

PROLOGO

En el apasionante cruce de la estadística, la economía y el análisis de series de tiempo, encontramos un conjunto de herramientas que permiten descifrar los misterios ocultos en los datos y tomar decisiones informadas en un mundo cada vez más impulsado por la información. Este libro es un faro que ilumina el camino a través de este intrincado terreno, ofreciendo una guía integral sobre cómo utilizar la regresión lineal, los modelos econométricos y el análisis de series de tiempo para comprender, predecir y modelar fenómenos económicos y financieros.

La estadística es el lenguaje de los datos, y la regresión lineal es una de sus herramientas más poderosas. En estas páginas, encontrarás una exploración profunda y clara de la regresión lineal, desde sus fundamentos hasta sus aplicaciones en la economía y las finanzas. Los autores han desglosado los conceptos complejos en explicaciones accesibles, utilizando ejemplos prácticos y ejercicios que te guiarán paso a paso en la construcción y evaluación de modelos de regresión.

Pero esto es solo el comienzo. Los modelos econométricos, que incorporan variables económicas y financieras, agregan un nivel adicional de sofisticación al análisis. Este libro te llevará a través de la teoría detrás de estos modelos y te mostrará cómo aplicarlos en situaciones del mundo real. Aprenderás a comprender y analizar la relación entre variables económicas, realizar pruebas de hipótesis y utilizar modelos econométricos para pronosticar tendencias y tomar decisiones estratégicas.

El análisis de series de tiempo, por su parte, es una herramienta esencial para comprender cómo los datos evolucionan a lo largo del tiempo. Este libro te llevará a través

de la modelización de series temporales, desde la identificación de patrones estacionales y tendencias hasta la construcción de modelos que permitan realizar predicciones precisas en un mundo en constante cambio.

Los autores de esta obra han combinado con maestría la teoría con la práctica. A medida que avanzas en las páginas de este libro, encontrarás ejemplos del mundo real que ilustran cómo estas herramientas pueden utilizarse para abordar problemas económicos y financieros reales. Descubrirás cómo aplicar estos métodos para tomar decisiones más informadas en contextos económicos, desde la inversión hasta la política pública.

Este libro es una invitación a un emocionante viaje a través del análisis de datos económicos y financieros utilizando la estadística, la regresión lineal, los modelos econométricos y el análisis de series de tiempo. Tanto si eres un estudiante de economía en busca de una comprensión más profunda, un analista financiero que busca mejorar sus habilidades o un profesional de la estadística interesado en el mundo económico, aquí encontrarás una guía valiosa y completa.

En un mundo cada vez más impulsado por los datos, la habilidad para entender y aprovechar estas poderosas herramientas es esencial. Este libro es tu brújula en este emocionante viaje. ¡Prepárate para embarcarte en un emocionante viaje hacia el mundo de la estadística aplicada y la toma de decisiones basada en datos!

INTRODUCCIÓN

En un mundo cada vez más impulsado por datos y cifras, la estadística se ha convertido en el idioma universal para descifrar los misterios ocultos en los números y extraer conocimiento valioso. En este emocionante viaje a través de la estadística, exploraremos una de las herramientas más versátiles y poderosas que existen: la regresión lineal. Pero no nos detendremos ahí. También adentraremos en el vasto territorio de los modelos econométricos y el análisis de series de tiempo, donde los datos financieros y económicos se convierten en nuestro lienzo para la exploración y la predicción.

La regresión lineal es la base sobre la cual se construyen muchos de los métodos estadísticos más avanzados. En su esencia, es una técnica que nos permite comprender y modelar la relación entre una variable de interés y una o más variables predictoras. A través de esta relación, podemos hacer predicciones, evaluar hipótesis y tomar decisiones informadas en una amplia variedad de campos, desde la ciencia social hasta la ingeniería, y, como lo veremos aquí, en el apasionante mundo de la economía y las finanzas.

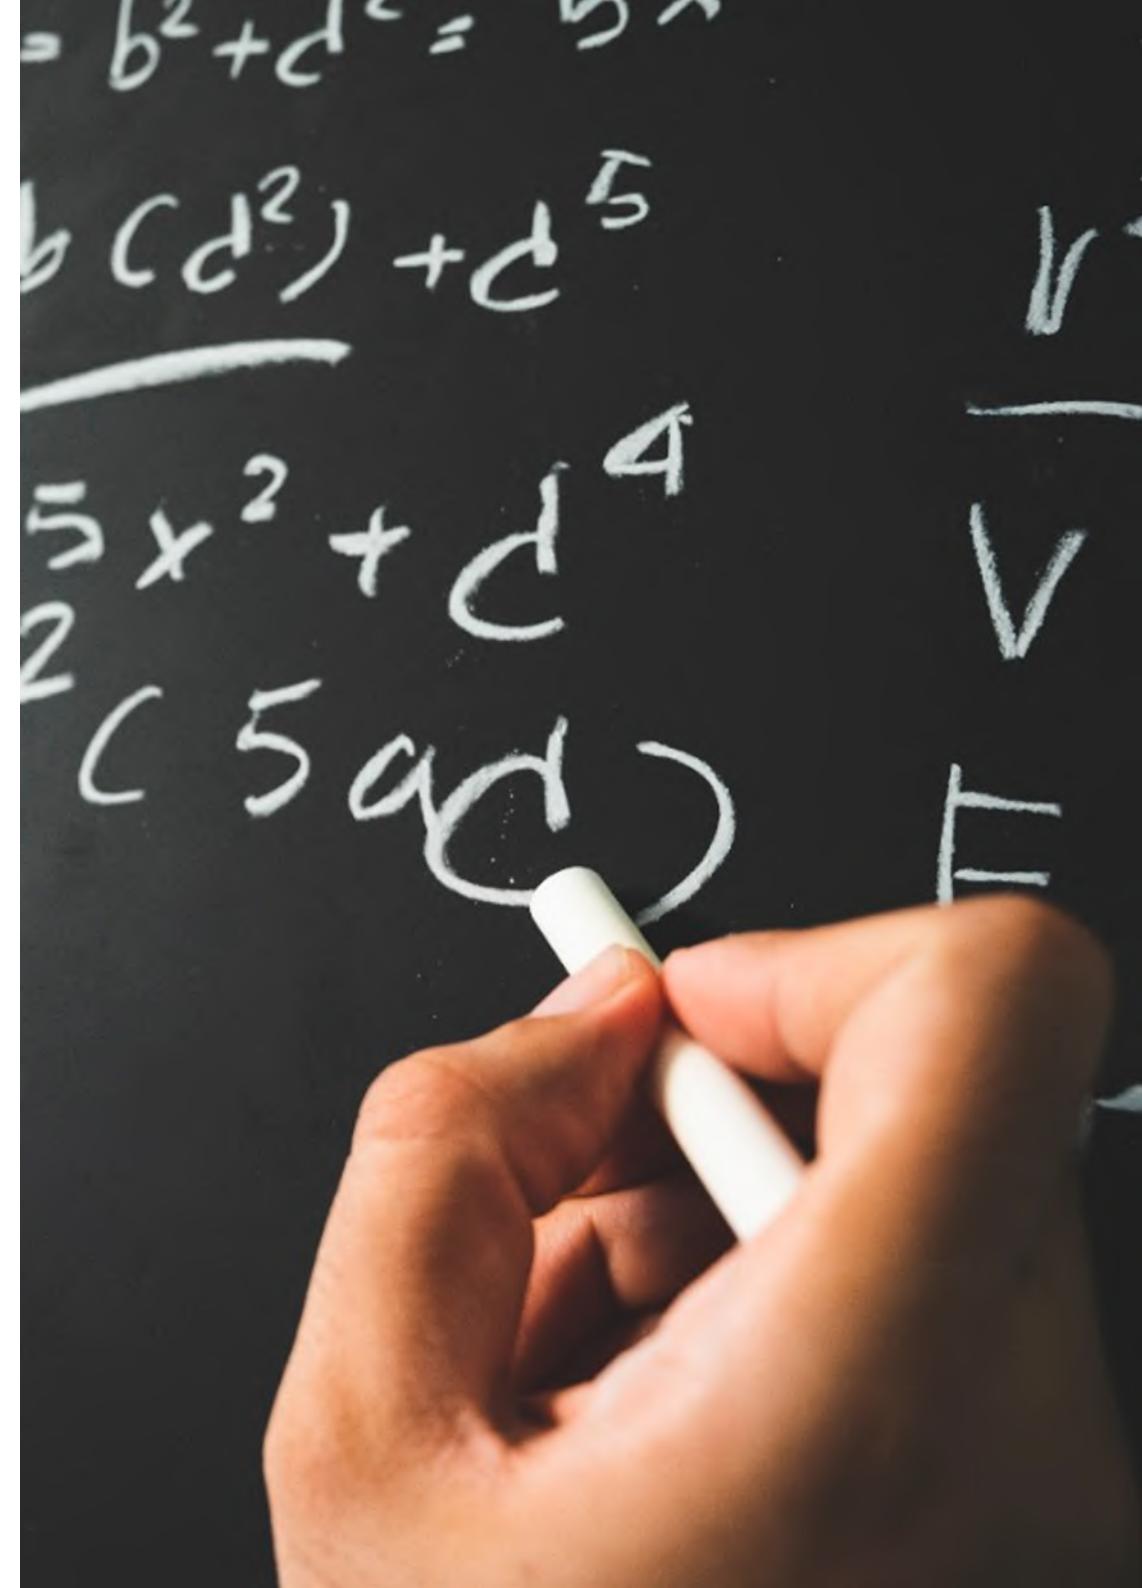
Los modelos econométricos, por su parte, son la culminación de la estadística aplicada a los datos económicos y financieros. Estos modelos permiten explorar y cuantificar las relaciones complejas que existen en estos dominios, teniendo en cuenta factores como la inflación, el crecimiento económico, las tasas de interés y muchas otras variables que afectan nuestra vida cotidiana. A medida que avanzamos en este libro, te mostraremos cómo utilizar modelos econométricos para comprender y predecir fenómenos económicos, evaluar políticas públicas y

tomar decisiones estratégicas en el ámbito financiero.

El análisis de series de tiempo, por último, es la herramienta que nos permite explorar cómo los datos evolucionan a lo largo del tiempo. En un mundo donde el tiempo es un factor crítico, entender las tendencias, los ciclos y las estacionalidades en los datos temporales es esencial. Aquí, te guiaremos a través de la identificación de patrones en series de tiempo, la construcción de modelos y la realización de predicciones precisas en contextos económicos y financieros.

A lo largo de este libro, encontrarás un equilibrio entre la teoría y la práctica. Hemos diseñado ejemplos del mundo real y ejercicios que te ayudarán a aplicar estos métodos de manera efectiva. Nuestra meta es proporcionarte las habilidades y el conocimiento necesarios para abordar problemas reales con confianza y precisión.

En un mundo donde los datos son la moneda del siglo XXI, la estadística, la regresión lineal, los modelos econométricos y el análisis de series de tiempo se convierten en herramientas esenciales para la toma de decisiones, la investigación y la comprensión del mundo que nos rodea. Este libro es tu entrada a este emocionante mundo, donde los números cobran vida y la estadística se convierte en tu aliada para explorar, entender y prever. ¡Bienvenidos a este viaje!



CAPÍTULO I

REGRESIÓN LINEAL MÚLTIPLE

El análisis de regresión lineal es una técnica estadística usada para estudiar la relación entre variables. Se adapta a una amplia variedad de situaciones y se enmarca en modelos lineales. Su objetivo es hallar una relación que describa o resuma la relación entre dos o más variables; por ejemplo: ¿cómo varía el promedio anual del maíz, según producción a nivel nacional? o ¿cómo varía el consumo de gasolina de un auto, según peso y potencia de su motor? En contexto de la investigación de mercados puede utilizarse para determinar en cuál de diferentes medios de comunicación puede resultar más eficaz invertir o predecir el número de ventas de un determinado producto.

En caso de dos, regresión simple, o más variables, regresión múltiple, el análisis de regresión lineal puede usarse para explorar y cuantificar la relación entre una variable llamada dependiente, endógena y una o más variables independientes, exógenas, así como desarrollar una ecuación lineal predictiva. Asocia una serie de procedimientos de diagnóstico, análisis de residuos y puntos de influencia respecto a estabilidad e idoneidad de análisis. Probablemente, es la técnica más usada para establecer relaciones funcionales entre variables a partir de una relación lineal de forma . $Y = X\beta + U$

Actualmente, es una herramienta metodológica cuantitativa y cualitativa que permite la asignación óptima de recursos escasos, apoyar eficientemente el proceso de toma de decisiones respecto a maximizar ganancias, utilidades, satisfacción de clientes o minimizar costos, distancias y tiempos. Hace uso de modelos matemáticos, que procesan datos, representan el problema real, establecen hipótesis que es una representación

precisa de la realidad tal que sus conclusiones sean válidas para resolver un problema práctico real; por ejemplo: cuánto producir con base en variables estocásticas-no estocásticas, dónde producir, a qué precio ofertar, a qué precio comprar materia prima, medios y rutas optimas de transporte.

Con base en información del Censo Nacional Agropecuario (CNA, 2000), Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC, 2002 a 2020) del Instituto Nacional de Estadística y Censos (INEC) del Ecuador a nivel Nacional, Regional, Provincial y Cantonal de cultivos permanentes, transitorios, producción animal, pastos y montes-bosques mediante uso de software con licencia (Microsoft Excel), open office (Python-Jupyter, R y R-Studio) e interactúa amplia y profundamente con Estadística para ingeniería, Diseño experimental para ingeniería e Investigación operativa para ingeniería, que paralelamente usan software con licencia y open office mencionados para desarrollo de ejercicios teóricos-prácticos complementarios.

1.1 Regresión lineal múltiple

La regresión lineal múltiple es una técnica estadística utilizada para analizar la relación entre una variable dependiente y dos o más variables independientes. En esta técnica, se busca encontrar una ecuación lineal que pueda predecir el valor de la variable dependiente en función de los valores de las variables independientes.

En otras palabras, la regresión lineal múltiple nos permite modelar una relación entre múltiples variables, lo que puede ser útil en una amplia variedad de contextos, como la predicción de

ventas en función de múltiples factores, el análisis de la relación entre el salario y la experiencia laboral y muchos otros casos.

Para realizar una regresión lineal múltiple, se requiere un conjunto de datos que incluya valores para la variable dependiente y para cada una de las variables independientes. A partir de estos datos, se puede ajustar un modelo de regresión lineal múltiple utilizando técnicas estadísticas para encontrar la mejor ecuación que se ajuste a los datos.

La regresión lineal múltiple es una herramienta poderosa para el análisis de datos, pero es importante tener en cuenta que no siempre es la mejor opción para todos los casos. Es necesario tener en cuenta las limitaciones de los datos y considerar otras técnicas de análisis de datos antes de decidir utilizar la regresión lineal múltiple.

1.1.1 Ejercicios Numéricos

Ejercicio 1. Dadas observaciones muestrales

Tabla 1. Observaciones muestrales

Y	1	1	-1	0	-2
X ₁	1	0	-1	0	0
X ₂	2	-1	2	-1	-2

Se propone ajustar modelo:

$$Y_i = \beta_1 + \beta_2 X_{i2} + \beta_3 X_{i3} + \varepsilon_i$$

a) ¿Cuáles son hipótesis comunes respecto a errores?

- b) Escriba matriz de diseño.
- c) Calcule estimadores de mínimos cuadrados de parámetros $\beta_1, \beta_2, \beta_3$.
- d) Estime
- e) Encuentre STC_(Suma Total de Cuadrados) y SEC_(Suma de Estimaciones al Cuadrado)
- f) ¿Qué hipótesis se prueba con razón, no se acepta H_0 a nivel de significancia?

1) Suponga que se tiene datos:

Tabla 2. Datos muestrales

Y	12	9	5	20	10	16
X ₁	10	5	7	19	11	18
X ₂	2	3	3	6	7	8

Su objetivo es estimar modelo:

$$Y_i = \beta_1 + \beta_2 X_{i1} + \beta_3 X_{i2} + \epsilon_i$$

Se ha estimado:

$$(X^t X)^{-1} = \begin{bmatrix} 1.0824 & -0.0465 & -0.0774 \\ \square & 0.0136 & -0.0233 \\ \square & \square & 0.0722 \end{bmatrix},$$

$$X^t Y = \begin{bmatrix} 72 \\ 978 \\ 384 \end{bmatrix},$$

$$STC_{\square} = 142$$

Donde la Suma Total de Cuadrados se representa por STC

- a) Estime vector $\hat{\beta}$
- b) ¿Cuál es el plano de regresión y cómo se interpreta los coeficientes?
- c) Estime y
- d) Si $\hat{Y} = (12.00, 6.17, 8.26, 18.93, 9.98, 16.66)$
- e) Estime SRC(Suma de Residuos al Cuadrado)
- f) Halle intervalo de confianza para β_2 con nivel de confiabilidad estadística 95%. Argumente si no aceptaría $H_0: \beta_2 = 0$ con nivel de significancia $\alpha=0.05$.
- g) Contraste hipótesis $H_0: \beta_3 = 0, H_a: \beta_3 \neq 0$ con nivel de significancia $\alpha=0.05$.
- h) Calcule ANOVA.
- i) Contraste hipótesis $H_0: \beta_2 = \beta_3 = 0, H_a: \beta_2 \neq 0$ o $H_1: \beta_3 \neq 0$ con nivel de significancia $\alpha=0.05$.

2) Se ajusta modelo de regresión lineal múltiple con dos regresores y 20 datos:

- a) Escriba modelo de regresión lineal con sus respectivas hipótesis.
- b) Calcule estimador de mínimos cuadrados de parámetros.
- c) Pruebe $H_0: \beta_3 = 0$ vs $H_a: \beta_3 \neq 0$ con nivel de significancia $\alpha=0.05$.

$$(X^t X)^{-1} = \begin{bmatrix} 0.1364 & -0.0682 & 0.0455 \\ 0.0682 & 0.1591 & -0.0227 \\ 0.0455 & -0.0227 & 0.1818 \end{bmatrix}, X^t Y = \begin{bmatrix} 3.1 \\ -3.3 \\ 2.2 \end{bmatrix}, STC_{\text{total}} = 4.23$$

d) Pruebe $H_0: \beta_2 + 2\beta_3 = 1$ vs $H_a: \beta_2 + 2\beta_3 \neq 0$ con nivel de significancia $\alpha = 0.05$.

e) Halle intervalo de confianza para $\beta_2 + 2\beta_3$ con nivel de confiabilidad estadística de 95%.

3) Con 28 datos se ajustan modelos de regresión lineal múltiple:

$$Y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \varepsilon_i$$

$$Y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \beta_5 x_{i5} + \varepsilon_i$$

Obteniéndose:

Tabla 4. Resultados parciales de 28 datos que se ajustan a modelos de RLM

Concepto	Modelo 1	Modelo 2
R^2	0.9955	0.9982
F	557.91	210.083

a) Estime R^2 corregido de cada modelo.

b) ¿Cuál es su interpretación respecto nulidad individual de parámetros para cada uno de los modelos?

Tabla 3. Datos que se ajustan a modelos de RLM

Regresor	Estimación	t	$\hat{\alpha}$	Estimación	t	$\hat{\alpha}$
Contante	7.65	6.17	1.6E-3	10.23	2.78	0.069
X_2	-5.11	-20.36	5.3E-6	-6.21	-4.21	0.023
X_3	12.15	33.27	4.6E-3	11.35	4.81	0.017
X_2^2				0.12	0.83	0.468
X_3^2				0.14	0.44	0.691

c) Estime intervalos de confianza de nivel 95% para B_2 para modelo 1 y 2. Justifique su conclusión.

d) ¿Cuál sería el nivel de confianza, del intervalo de confianza más corto que contiene al cero, para B_3 en cada uno de los modelos?

e) A nivel de significancia de 5% pruebe que hipótesis $H_0: \beta_5 = \beta_4 = 0$ vs $H_a: \beta_5 \neq 0$ o $\beta_4 \neq 0$

f) Argumente qué modelo prefiere y por qué.

g) Con base en información dada, pruebe siguientes hipótesis:

i. $H_0: \beta_4 = 0$ vs $H_a: \beta_4 \neq 0$

ii. $H_0: \beta_3 = \beta_5 = 0$ vs $H_a: \beta_3 \neq 0$ o $\beta_5 \neq 0$

4) Con base en 32 observaciones se estimó:

$$y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \beta_5 x_{i5} + u_{ia})$$

a) Si probabilidades críticas, , para pruebas de nulidad de

parámetros $H_0: \beta_j = 0$ son:

Tabla 5. Probabilidades críticas, , para pruebas de nulidad de parámetros

$$H_0: \beta_j = 0$$

x^2	x^3	x^4	x^5
0.027	0.202	0.005	0.004

Argumente su conclusión.

b) Si cuenta con base de datos, describa por pasos cómo procedería para probar hipótesis $H_0: \beta_3 = \beta_4 = 0$ vs $H_a: \beta_3 \neq 0$ o $\beta_4 \neq 0$

c) Para contrastar hipótesis $H_0: \beta_3 = \beta_4 = 0$ vs $H_a: \beta_3 \neq 0$ o $\beta_4 \neq 0$ tal que la Suma de Residuos al Cuadrado sería:

$$\text{SRC} \square (\beta_1, \beta_2, \beta_3, \beta_4, \beta_5) = 21,706.0,$$

$$\text{SRC } \square (\beta_1, \beta_2, \beta_3) = 74,056.6.$$

Argumente su conclusión si no aceptaría H_0 con $\alpha=0.05$

Suponga que usa modelo de regresión para relacionar una respuesta con cuatro regresores. Si $n=2$, justifique su conclusión respecto al menor valor de R^2 para regresión sea significativa con $\alpha=0.05$. Use razón F en función de R^2 .

1.2 Encuesta de superficie y producción agropecuaria continua (ESPAC) 2000-2020

Las características directamente observadas sobre el terreno, como superficie de los cultivos y demás usos del suelo, la superficie regada con cada tipo de riego y la superficie labrada

con cada técnica de laboreo, se estiman con base en datos recogidos en la muestra de segmentos.

Las variables relativas a economía de unidades de producción agropecuaria, incluyendo ganadería y variables relativas al hogar, han de ser estimadas a partir de los datos recogidos mediante entrevistas a los agricultores y sus hogares. Las estimaciones basadas en muestra de segmentos indica que total Y de variable en estudio se expresa como suma de los totales, Y_h , de cada estrato

$$Y = \sum_{h=1}^L Y_h$$

Los estimadores de dominio basados en muestra original definen a variable auxiliar:

$$\hat{y}_{hij} = \begin{cases} Y_{hij} & \text{si } i \in \text{Dom D} \\ 0 & \text{en otro caso} \end{cases}$$

$$\hat{Y}_D = \sum_{h=1}^L \hat{Y}_{Dh} \text{ tal que } \hat{Y}_{Dh} = \sum_{j=1}^{m_h} \hat{Y}_{Dhj}$$

Del total de variable en estrato h dentro del dominio . El estimador del total de variable en estudio en j-ésima zona del estrato h-ésimo , en dominio:

$$\hat{Y}_{Dhj} = \left[\left(\frac{N_{hj}}{r_h} \right) \left(\sum_{r=1}^{r_h} y'_{hij} \right) \right]$$

Varianza del estimador del total de dominio está dado por

$$\text{Var}(\hat{Y}_D) = \sum_{h=1}^L [\text{V}(\hat{Y}_{Dh})] \text{ tal que } \text{Var}(\hat{Y}_{Dh}) = \sum_{j=1}^{m_h} [\text{V}(\hat{Y}_{Dhj})]$$

$$\Rightarrow \sum_{j=1}^{m_h} \left[(N_{hj}^2) \left(\left(1 - \frac{r_h}{N_{hj}} \right) \left(\frac{1}{r_h} * \frac{1}{N_{hj}-1} \right) \left(\sum_{i_x=1}^{N_{hj}} (y'_{hij} - \bar{Y}'_{hj})^2 \right) \right) \right]$$

$$\Rightarrow \sum_{j=1}^{m_h} \left[(N_{hj}^2) \left(\left(1 - \frac{r_h}{N_{hj}} \right) \left(\frac{1}{r_h} * \frac{1}{r_h-1} \right) \left(\sum_{i=1}^{r_h} (y'_{hij} - \bar{y}'_{hj})^2 \right) \right) \right]$$

$$\Rightarrow \sum_{j=1}^{m_h} \left[(N_{hj}^2) \left(\left(1 - \frac{r_h}{N_{hj}} \right) \left(\frac{1}{r_h} * \frac{1}{r_h-1} \right) \left(\sum_{i=1}^{r_h} \left(y'_{hij} - \left(\frac{1}{r_h} * \sum_{i_x=1}^{r_h} y'_{hij} \right) \right)^2 \right) \right) \right]$$

Se estima por:

$$[\hat{V}(\hat{Y}_D)] = \sum_{h=1}^L [\hat{V}(\hat{Y}_{Dh})] \Rightarrow \sum_{h=1}^L \sum_{j=1}^{m_h} [\hat{V}(\hat{Y}_{Dhj})]$$

$$\Rightarrow \sum_{h=1}^L \sum_{j=1}^{m_h} \left[(N_{hj}^2) \left(\left(1 - \frac{r_h}{N_{hj}} \right) \left(\frac{1}{r_h} \right) \right) \right]$$

$$* \frac{1}{N_{hj}-1} \left(\sum_{i_x=1}^{N_{hj}} \left(y'_{hij} - \left[\left(\frac{1}{N_{hj}} \right) \left(\sum_{i=1}^{N_{hj}} y'_{hij} \right) \right]^2 \right) \right)$$

Varianza del estimador de media es:

$$V(\hat{\bar{Y}}_{Dh}) = \left[\left(\frac{1}{N_D^2} \right) (V(\hat{Y}_D)) \right]$$

$$\hat{V}(\hat{\bar{Y}}_{Dh}) = \left[\left(\frac{1}{N_D^2} \right) (\hat{V}(\hat{Y}_D)) \right]$$

Se estima por coeficientes de variación total y media, que coinciden. Los estimadores de dominio basados en muestras múltiples se calculan, pues si no alcanza el nivel requerido, entonces es necesario complementar la muestra original con una muestra adicional seleccionada dentro del dominio en cuestión.

Se considera el problema de estimar el total de dominio de una variable de muestreo, Y_D , a partir de dos muestras, inicial de la ESPAC, y complementaria, B. Las muestras se seleccionan sucesivamente de sendos marcos $\{A, B\}$ tal que primero se muestrea A y después B. Los tamaños de los estratos en ambos marcos son conocidos a priori:

$$\left\{ N_h^{(A)} ; h = 1, 2, 3, 4 \dots, L \right\} \text{ con } \sum_{h=1}^L N_h^{(A)} = N_A \text{ y } \left\{ N_h^{(B)} ; h = 1, 2, 3, 4 \dots, L \right\} \text{ con } \sum_{h=1}^L N_h^{(B)}$$

$$= N_B$$

Se sabe que N_A es número de unidades de muestreo en el marco A y N_B . y es número de unidades de muestreo en el marco B.

Generalmente, el marco B es parte de marco A dentro de los límites del dominio D. Por ejemplo, si el dominio D es un cantón o una provincia, N_B es el número de segmentos del marco A que están dentro del dominio D:

$$\left\{ h^{(A)} ; h = 1, 2, 3, 4 \dots, L \right\} \text{ y } \left\{ h^{(B)} ; h = 1, 2, 3, 4 \dots, L \right\}$$

Sin embargo, los criterios de estratificación de B pueden ser distintos de A y, en ese caso, los estratos coincidirán. Si los criterios de estratificación de B son igual a A :

$$N_{h^{(A)}h^{(B)}} = 0; \forall \{h^{(A)}, h^{(B)} | h^{(A)} \neq h^{(B)}\}, N_{h^{(B)}} = N_{h^{(A)}h^{(B)}}, \forall h^{(A)} = h^{(B)}$$

$$N_{h^{(A)}h^{(B)}} + N_{h^{(A)}(L+1)^{(B)}} = N_{h^{(A)}}, \forall \{h = 1, 2, 3, 4 \dots, L\}$$

El estimador del total es tal que valor de variable en estudio en i-ésimo-elemento de población en:

$y_{h^{(A)}h^{(B)}}$ estrato $H^{(A)}H^{(B)}$

El total de dominio será:

$$Y_D = \sum_{h^{(A)}=1}^{L^{(A)}} \sum_{h^{(B)}=1}^{L^{(B)}} (Y_{h^{(A)}h^{(B)}})$$

$$\Rightarrow Y_D = \sum_{h^{(A)}=1}^{L^{(A)}} \sum_{h^{(B)}=1}^{L^{(B)}} \sum_{i=1}^{N_{h^{(A)}h^{(B)}}} [y_{h^{(A)}h^{(B)}}] \text{ es dominio en estrato } y_{h^{(A)}h^{(B)}}$$

Varianza de estimador de \hat{Y}_B está dado por:

$$\text{Var}(\hat{Y}_B) = \sum_{h^{(A)}=1}^{L^{(A)}} \sum_{h^{(B)}=1}^{L^{(B)}} [\text{V}(\hat{Y}_{h^{(A)}h^{(B)}})] \Rightarrow \text{Var}(\hat{Y}_B)$$

$$= \sum_{h^{(A)}=1}^{L^{(A)}} \sum_{h^{(B)}=1}^{L^{(B)}} \left[\sum_{i=1}^{N_{h^{(A)}h^{(B)}}} \left(\left(\frac{1 - \bar{w}_{(i)h^{(A)}h^{(B)}}}{\bar{w}_{(i)h^{(A)}h^{(B)}}} \right) \left(y_{h^{(A)}h^{(B)}}^2 \right) + \right) \right]$$

A

O, equivalente a:

$$\sum_{h(A)=1}^{l(A)} \sum_{h(B)=1}^{l(B)} \left[\left(\frac{1}{2} \right) \left(\sum_{i=1}^{N_{h(A)h(B)}} \left(\left(\bar{\omega}_{(\pi)h(A)h_i^{(B)}} - \bar{\omega}_{(\pi)h(A)h_i^{(B)}} \bar{\omega}_{(\pi)h(A)h_i^{(B)}} \right) \left(\frac{y_{h(A)h_i^{(B)}}}{\bar{\omega}_{(\pi)h(A)h_i^{(B)}}} - \frac{\bar{\omega}_{(\pi)h(A)h_i^{(B)}}}{\bar{\omega}_{(\pi)h(A)h_i^{(B)}}} \right)^2 \right) \right) \right]$$

Estimador de varianza del estimador se calcula siempre que

$$\bar{\omega}_{(\pi)h(A)h_i^{(B)}} > 0; \forall i, i' \quad \text{estimador insesgado } (\bar{Y}_{h(A)h(B)}) \quad \text{y}$$

será

$$\hat{V}\bar{Y}_{h(A)h(B)} = \sum_{i=1}^{N_{h(A)h(B)}} \left(\frac{1 - \bar{\omega}_{(\pi)h(A)h_i^{(B)}}}{\bar{\omega}_{(\pi)h(A)h_i^{(B)}}} \right) \left(\frac{y_{h(A)h_i^{(B)}}^2}{\bar{\omega}_{(\pi)h(A)h_i^{(B)}}} \right)$$

En ocasiones, esta varianza es negativa tal que se toma como estimación de varianza en valor cero. Con muestras simples:

$$\bar{\omega}_{(\pi)h(A)h_i^{(B)}} = 1 - (1 - f_h^{(A)})(1 - f_h^{(B)}) = \bar{\omega}_{h(A)h(B)}; \forall i$$

Además:

$$\begin{aligned} \bar{\omega}_{(\pi)h(A)h_i^{(B)}} &= (\bar{\omega}_{(\pi)h(A)h_i^{(B)}})(\bar{\omega}_{(\pi)h(A)h_i^{(B)}}) \\ &= 1 - (1 - \tilde{f}_h^{(A)})(1 - \tilde{f}_h^{(B)}) \\ &= \tilde{\omega}_{h(A)h(B)}; \forall i, i' \end{aligned}$$

Y:

$$\begin{aligned} \bar{\omega}_{(\pi)h(A)h_i^{(B)}} &= (\bar{\omega}_{(\pi)h(A)h_i^{(B)}})(\bar{\omega}_{(\pi)h(A)h_i^{(B)}}) \\ &= 1 - \left(1 - \frac{n_h^{(A)}}{N_h^{(A)} - 1} \right) \left(1 - \frac{n_h^{(B)}}{N_h^{(B)} - 1} \right) \\ &= \tilde{\omega}_{h(A)h(B)}; \forall i, i' \end{aligned}$$

Es decir:

$$\begin{aligned} &= \tilde{\omega}_{h(A)h(B)}; \forall i, i' \\ \hat{V}\bar{Y}_{h(A)h(B)} &= \left[\left(\frac{1 - \bar{\omega}_{h(A)h(B)}}{\bar{\omega}_{h(A)h(B)}} * \frac{1}{\bar{\omega}_{h(A)h(B)}} \right) \left(\sum_{i=1}^{N_{h(A)h(B)}} [y_{h(A)h_i^{(B)}}^2] \right) \right] \\ &\quad + \left[\left(\frac{\bar{\omega}_{h(A)h(B)} \tilde{\omega}_{h(A)h(B)} - \bar{\omega}_{h(A)h(B)} \bar{\omega}_{h(A)h(B)}}{\bar{\omega}_{h(A)h(B)} \bar{\omega}_{h(A)h(B)}} \right) \right. \\ &\quad \left. * \frac{1}{\bar{\omega}_{h(A)h(B)} \tilde{\omega}_{h(A)h(B)}} \right) \left(\sum_{i=1}^{N_{h(A)h(B)}} \sum_{i'(\neq i)=1}^{N_{h(A)h(B)}} (y_{h(A)h_i^{(B)}} * y_{h(A)h_i'^{(B)}}) \right) \end{aligned}$$

1.3 Ejercicios Teóricos

5) Suponga se tiene regresores y quiere ajustar

$$Y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \beta_5 x_{i5} + \cdots + \beta_p x_p + u_i$$

a) Escriba hipótesis típicas respecto a errores.

b) Escriba sistema normal de ecuaciones para hallar estimadores de mínimos cuadrados ordinarios.

c) Si $\bar{y} \neq 0$ y $1_n \notin \text{img}_{(\text{Imagen})}(X)$,

demuestre que vectores $(Y - \bar{Y}1_n), (Y - \bar{Y})$ no son ortogonales. Concluya:

$$\sum_{i=1}^n (Y_i - \hat{Y})^2 \neq \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

d) Justifique en todos los casos:

$$\sum_{i=1}^n Y_i^2 = \sum_{i=1}^n \hat{Y}_i^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

e) Justifique si grados de libertad de sumas de cuadrados anteriores son: $n, p, n-p$, respectivamente.

6) Considere modelo de regresión lineal múltiple:

$$Y_i' = \beta_1' + \sum_{j=2}^k \beta_j' x_{ij}' + \varepsilon_i \quad i = 1, 2, 3, 4, \dots, n$$

a) ¿Cuáles son hipótesis sobre errores?

b) Demuestre que:

$$\hat{\beta}_1 = \bar{Y} - \sum_{j=2}^k \hat{\beta}_j \bar{x}_j$$

Tal que $\{\hat{\beta}_i\}$ son estimadores de mínimos cuadrados,

\bar{Y}, \bar{x}_i son promedios.

c) Demuestre que si se centra todas las variables:

$$Y_i' = Y_i - \bar{Y}, x_{ij}' = x_{ij} - \bar{x}_j \quad \forall i, j$$

Se obtiene modelo:

$$Y_i' = \beta_1' + \sum_{j=2}^k \beta_j' x_{ij}' + \varepsilon_i \quad i = 1, 2, 3, 4, \dots, n$$

donde;

$$\beta_1' = \beta_1 - \left(\bar{Y} - \sum_{j=2}^k \beta_j \bar{x}_j \right), \beta_j' = \beta_j \quad j \geq 1$$

Con base en modelo anterior, demuestre que estimador de mínimos cuadrados de β_1 es $\hat{\beta}_1 = \mathbf{0}$. Significa que se puede centrar variables y estimar un modelo sin término constante, para después estimar constante con fórmula dada en

7) Sea matriz de diseño escrita por columnas:

$$X = [1_n, X_{(1)}, X_{(2)}, X_{(3)}, X_{(4)}, \dots, X_{(k)}]$$

Suponga que columnas de matriz son ortogonales; es decir, el producto escalar de dos columnas diferentes es nulo.

a) Estime matriz $X^t X$

b) Demuestre:

$$\hat{\beta}_1 = \bar{y}_1, \hat{\beta}_j = \left[\frac{X_{(j)}^t Y}{\|X_{(j)}\|^2} \right] \quad j = 1, 2, 3, 4, \dots, k$$

c) Demuestre:

$$SRC_{(\text{Suma de Residuos al Cuadrado})} = Y^t Y - \sum_{j=2}^k \hat{\beta}_j X_{(j)}^t Y$$

a) Suponga que vector β se parte de dos sub vectores β^1 , contiene primeras componentes y β^2 , contiene componentes restantes. Su objetivo es probar hipótesis $H_0: \beta^2 = 0$ vs $H_1: \beta^2 \neq 0$.

i. Demuestre que suma de cuadrados de residuos sujetos

a restricción $\beta^2=0$ es:

$$\text{SEC}_{(\text{Suma de Estimaciones al Cuadrado})}(0) = Y^t Y - \sum_{j=2}^k \hat{\beta}_j X_{(j)}^t Y$$

ii. Escriba razón F.

- 8) Considere modelo lineal $Y = X\beta + \varepsilon$, sea $\hat{\beta} = X^t X (X^t X)^{-1}$ el estimador de mínimos cuadrados β . Suponga que todas las variables explicativas sufren un cambio de escala; es decir, se les multiplica por una constante no nula:

$$Z_j = \lambda_j X_j, \quad \lambda_j > 0, \quad j = 2, 3, 4, \dots, k$$

Así se tiene un nuevo mc $Y = X\beta + \varepsilon$, sea $\hat{\beta} = X^t X (X^t X)^{-1}$

estimador de mínimos cuadrados de γ (Letra griega minúscula gamma). Demuestre:

a) $\hat{\lambda} = \Lambda_{(\Lambda)}^{-1} \hat{\beta}$ con $\Lambda_{(\Lambda)}^{-1} = \text{diag}_{(\text{Diagonal})}\{1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \dots, \lambda_k\}$

$X\hat{\beta} = Z\hat{Y}$ (Letra griega minúscula gamma)

c) Concluya que SRC(Suma de Residuos al Cuadrado) no cambia y razón F tampoco. Se sugiere que escriba Z como producto de matriz X por otra matriz que debe determinar.

9) Estime derivadas parciales:

$$\text{SRC}_{(\text{Suma de Residuos al Cuadrado})}(b_2, b_3, b_4, b_5, \dots, b_k)$$

$$= \sum_{i=1}^n (Y_i - b_1 - b_2 x_{i2} - b_3 x_{i3} - b_4 x_{i4} - \dots - b_k x_{ik})^2$$

Iguale a cero y demuestre que el sistema de ecuaciones obtenido puede escribirlo en forma $X^t X \hat{\beta} = X^t Y$.

10) Sea X matriz $(n*k)$ de rango $k < n$, $F = \text{img}_-(X)$, Y un vector de R^n . Use definición de vectores ortogonales, con base a producto interno para demostrar que proyección ortogonal de Y sobre F es $\hat{Y} = X^t X Y (X^t X)^{-1}$

11) Demuestre

Lema. Si C es de rango completo,

$$\text{SRC}_{(0)} = \text{SRC}_{\square} + \left(\hat{\Psi}_{\square} - \Psi_0 (\text{Vector fijo de } R^q) \right)^t (S^{-1}) \left(\hat{\Psi}_{\square} - \Psi_0 (\text{Vector fijo de } R^q) \right)$$

Tal que $\hat{U}^0 = Y - X\hat{\beta}^0$, $\text{SRC}_{(0)} = (\hat{U}^0)^t (\hat{U}^0)$ es suma de residuos al cuadrado bajo H_0 .

12) Demuestre $\bar{R}^2 \leq R^2$

13) Verifique $\text{Var}(\hat{\beta}_1) = \left(\frac{\sigma^2}{n} \right) [1 + \bar{x}^t S_{xx}^{-1} \bar{x}]$ donde $\bar{x}^t = (\bar{x}_2, \bar{x}_3, \bar{x}_4, \bar{x}_5, \dots, \bar{x}_k)$

14) Sea X_1, X_2, \dots, X_n una muestra de $N_k(\theta u_0, \sigma^2 I)$ tal que θ es parámetro real desconocido u_0 , es un vector conocido de R^k , $\sigma^2 \in R^{(+)}$.

a) Demuestre:

$$\hat{\theta} = \left[\frac{u_0^t \bar{X}}{u_0^t u_0} \right] \Rightarrow \text{Es estimador de máxima verosimilitud de } \theta$$

b) Verifique:

$$\text{Var}(\hat{\theta}) = \left[\frac{\sigma^2}{n u_0^t u_0} \right]$$

15) Considere modelo:

$$Y = X\beta + U; E(U) = 0, \text{Var}(U) = \sigma^2 I$$

Suponga matriz X es $(n \times k)$ de rango k , esta dada por

$X = \begin{bmatrix} I_k \\ 0 \end{bmatrix}$ tal que I_k es matriz identidad $(k \times k)$. Sea $A_{(n \times k)}$ de rango k , definida:

$$A = \begin{bmatrix} I_k \\ L \end{bmatrix}, L = \begin{bmatrix} 0 & \cdots & 0 & 1 \\ \vdots & \ddots & \vdots & \vdots \\ 0 & \cdots & 0 & 1 \end{bmatrix}$$

Considere estimadores:

$$\hat{\beta} = X^t Y (X^t X)^{-1} \quad \hat{\beta} = A^t Y$$

- a) Determine explicitamente los estimadores
- b) Verifique es lineal insesgado
- c) ¿Puede aplicar teorema de Gauss-Markov para decidir cuál de dos estimadores es mejor?
- d) Estime varianza de dos estimadores
- e) Demuestre directamente que $m_{\frac{\text{Var}(\hat{\beta}) - \text{Var}(\hat{\beta})}{\text{Var}(\hat{\beta}) - \text{Var}(\hat{\beta})}}$ es semi definida positiva
- f) Existe contradicción entre literales ¿Puede aplicar teorema de Gauss-Markov para decidir cuál de dos estimadores es mejor y demuestre directamente que $m_{\frac{\text{Var}(\hat{\beta}) - \text{Var}(\hat{\beta})}{\text{Var}(\hat{\beta}) - \text{Var}(\hat{\beta})}}$ es semi definida positiva?

Verifique que

$$\bar{R}^2 \leq R^2$$

CAPÍTULO II

INTRODUCCIÓN A MODELOS ECONOMÉTRICOS

2.1. Cobb-Douglas

La mayor parte de análisis de empresas, en inversiones, parten de que existe una dependencia entre producción y capital productivo para asegurar la producción. El nivel de capital, necesario, no se determina únicamente en función de producción sino de precios y costos productivos.

La combinación de estos factores se determina a partir de una función de producción tipo Cobb-Douglas:

$$P_t = \alpha C_t^{\beta_2} T_t^{\beta_3} e^{(u_t)}$$

Otra forma de escribir este modelo, con base en relaciones que representan procesos productivos en que no interviene el comportamiento de los agentes económicos, es:

$$P_{(\text{Producción total})} = c K_{(\text{Capital económico})}^a + L_{(\text{Mano de obra})}^b$$

Donde;

P_t : Producción

α : Parámetro

$C_t^{\beta_2}$: Insumo capital

$T_t^{\beta_3}$: Insumo trabajo

$e^{(u_t)}$: Error

En general, estas observaciones son periódicas tal que el uso de subíndice en vez de . Esta relación no es lineal ni en parámetros ni en variables, pero se transforma en una relación lineal, en parámetros, tomando logaritmos naturales en ambos lados:

$$\ln[P_t] = \beta_{(1)} + \beta_{(2)} \ln[C_t] + \beta_{(3)} \ln[T_t] + u_t$$

Esto permite estimar parámetros $\beta(j)$ por métodos de regresión lineal múltiple, el estimador de constante α (Parámetro) $\hat{\alpha} = e^{\hat{\beta}_{(1)}}$ es aunque, es sesgado.

Es fácil probar que si mantiene constante el insumo trabajo:

$$\left[\frac{\left(\frac{dP_t}{P_t} \right)}{\left(\frac{dC_t}{C_t} \right)} \right] = \beta_{(2)}$$

Esto demuestra que $\beta_{(2)}$ es elasticidad-capital de producción. Se interpreta como “si capital aumenta, o disminuye, en 1% e insumo trabajo se mantiene constante; entonces, el volumen de producción aumenta, o disminuye, en $\beta_{(2)}$ %. $\beta_{(3)}$. es elasticidad-trabajo de producción, si insumo capital se mantiene constante $\beta_{(2)} + \beta_{(3)}$. ofrece información respecto a rendimientos escala; es decir, es la respuesta proporcional de producción a cambios en insumos capital y trabajo. Si multiplica insumos por una constante, °(Constante) , la variación de producción sería:

$$\frac{P_{(t+1)}}{P_t} = C_t^{(\beta_{(2)} + \beta_{(3)})}$$

Si $(\beta_{(2)} + \beta_{(3)}) = 1$ indica que producción se multiplica por °(Constante) . Su interpretación indica que tienen rendimientos constantes a escala.

Si $(\beta_{(2)} + \beta_{(3)}) > 1$ señala que rendimientos son crecientes a escala y, finalmente,

Si $(\beta_{(2)} + \beta_{(3)}) < 1$ muestra rendimientos decrecientes a escala. En este modelo, es importante probar, con nivel de significancia , si $(\beta_{(2)} + \beta_{(3)}) = 1$, $(\beta_{(2)} + \beta_{(3)}) > 1$ o $(\beta_{(2)} + \beta_{(3)}) < 1$.

2.2.Funciónde consumo

La tasa de crecimiento de volumen de consumo ($C_{(Tasa\ de\ crecimiento\ de\ volumen\ de\ consumo)}$) de hogares en un trimestre es función de tasa de crecimiento del poder de compra (I) y tasa de crecimiento del índice de precios (P) ; es decir, de inflación:

$$\left(\frac{\Delta C}{C} \right)_t = \beta_{(1)} + \beta_{(2)} \left(\frac{\Delta I}{I} \right)_t + \beta_{(3)} \left(\frac{\Delta P}{P} \right)_t + \varepsilon_{(i)}$$

Tal que:

$$\left(\frac{\Delta C}{C} \right)_t = \left[\frac{C - C_{(t-1)}}{C} \right]$$

Las otras son similares. El consumo no es una función lineal de ingreso ni índice de precios, pero sí de sus tasas. El error, por hipótesis es aleatorio, puede cubrir muchos fenómenos de naturaleza diferente. Primero, responderá a errores de observación. Segundo, se deberá a otras variables no incluida

en modelo.

Por ejemplo: volumen ahorrado a inicio de trimestre, las variaciones en presión fiscal, hábitos de consumo y expectativas de jefes de hogar. El modelo retenido tendrá sentido sólo si influencia de variables no incluidas tienen comportamiento secundario respecto a influencia de variables principales, ingresos y precios.

Interpretación:

Coeficientes

$\beta_{(2)}$ (Elasticidad-ingreso de consumo cuando precios se mantienen constantes)

$\beta_{(3)}$ (Elasticidad-ingreso de consumo cuando ingresos se mantienen constantes), miden cambios porcentuales entre variables.

2.3. Estructura de consumo

El consumo de hogares en un año ($t=1,2,3,4,\dots,T$) puede descomponerse en grupos de bienes y servicios G_i ($i=1,2,3,4,\dots,N$). A instante el consumo total (C_T) de hogares se reparte entre grupos G_i de forma que se denomina (p_i) a precio unitario del grupo G_i , en cada grupo existe un volumen de consumo pre-asignado β_i , el consumo pre-asignado en cada grupo ($\beta_i p_i$). El consumo total no es suma de consumos pre-asignados la diferencia está dada:

$$C_T = \sum_{i=1}^N (\beta_i p_i)$$

Suponga que esta diferencia se reparte entre diferentes grupos de bienes y servicios en proporciones ($\gamma_1, \gamma_2, \gamma_3, \gamma_4, \dots, \gamma_N$). Al grupo G_i le corresponde:

$$(\gamma_i) \left[C_T - \sum_{i=1}^N (\beta_i p_i) \right]$$

Si es volumen de consumo total en grupo G_i para cada periodo t se tiene modelo no lineal:

$$p_i q_i = \beta_i p_i + (\gamma_i) \left[C_T - \sum_{i=1}^N (\beta_i p_i) \right] + u_i$$

Coeficientes que intervienen son $\beta_i, \gamma_i, \beta_i \gamma_i$.

2.4. Curva de Phillips

La curva de Phillips describe relación entre tasa de salarios nominales (Y) y tasa de desempleo (X):

La tasa de desempleo que corresponde a tasa de salarios nula es llamada :

$$\beta_1 + \left[(\beta_2) \left(\frac{1}{X_{(tnd)}} \right) \right] = 0 \rightarrow X_{(tnd)} = - \left[\frac{(\beta_2)}{(\beta_1)} \right]$$

Los signos esperados son negativos (β_1), y positivo (β_2), tal que el cociente de fórmula $- \left[\frac{(\beta_2)}{(\beta_1)} \right]$, es positivo. La curva tiene una asíntota en $Y=(\beta_1)$:

$$\lim_{x \rightarrow \infty} (\beta_1) + \left[(\beta_2) \left(\frac{1}{X_{(t)}} \right) \right] = \beta_1$$

Si tasa de desempleo crece mucho, tasa de salario tiende a mantenerse constante, como se espera que (β_1) sea negativo, indica que salario disminuye a una tasa semejante a $|\beta_1|$.

La variación de tasa de salario disminuye con cuadrado de tasa de desempleo:

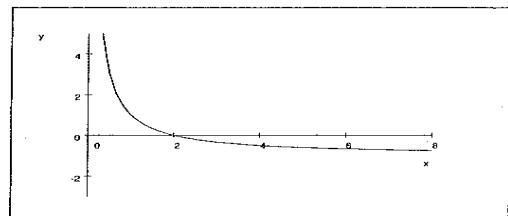
$$\frac{d(y_t)}{d(x_t)} = - \left[\frac{(\beta_2)}{(x_t^2)} \right]$$

Punto $X_{(tnd)}$ juega un rol importante, pues es punto donde variación de tasa de salarios decrece de forma notable. Para $X < X_{(tnd)}$ salarios decrecen a tasas “notablemente” más altas que $X > X_{(tnd)}$. Para curva del gráfico de tasa natural de desempleo es 2.

Cuando tasa de desempleo aumenta, salarios disminuyen a una tasa semejante a 1%. La tasa de salarios decrece al ritmo:

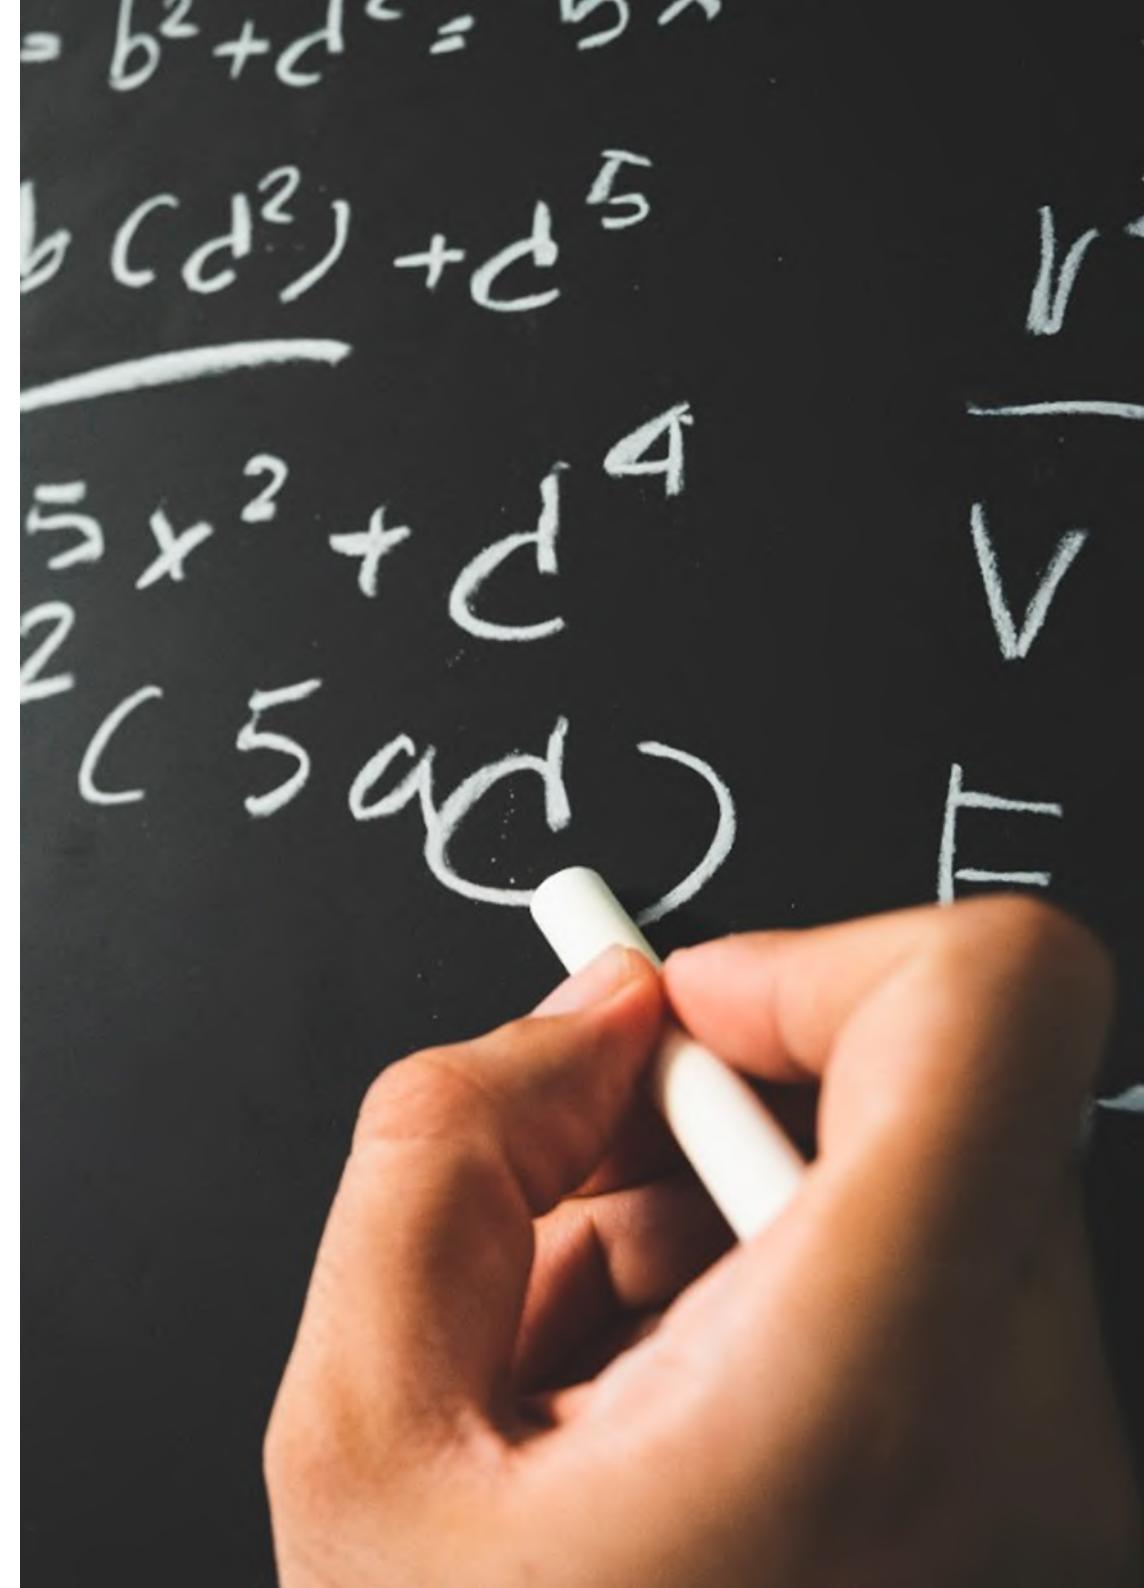
Por ejemplo, si,

$$\frac{d(y_t)}{d(x_t)} = - \left[\frac{(\beta_2)}{(x_t^2)} \right]$$



Curva $y = -1 + 2/x$

Figura 1. Curva de Phillips describe relación entre tasa de salarios nominales y tasa de desempleo



CAPÍTULO III

3.1. Introducción

INTRODUCCIÓN A MODELOS INTRODUCCIÓN A SERIES DE TIEMPO

Para el análisis de series de tiempo existen varios enfoques; aunque, ninguno puede decir que es mejor que restantes.

Refiere al más simple, que es identificar principales factores que parecen influir en sus valores individuales y examina métodos de predicción agrupados bajo el nombre genérico de métodos de suavizado o atenuación.

En análisis de fenómenos físicos económicos o financieros se dispone de cierta cantidad de observaciones de una variable aleatoria numérica, tomadas en momentos equidistantes tal que estos datos tienen propiedades interesantes.

Definición. Conjunto de datos ordenados en tiempo y han sido tomados a intervalos equidistantes en tiempo. Es llamada serie histórica, serie cronológica o datos de panel; por ejemplo:

- a) Temperatura promedio diaria durante un año.
- b) Inicio mensual de precios al consumidor (IPC).
- c) Precios de venta de ciertos artículos de temporada.
- d) Caudal promedio diario de un río.

Si observaciones de un fenómeno se hacen mediante tiempo es posible que presenten esquemas que se repitan periódicamente y observaciones contiguas sean, probablemente, dependientes. Las series cronológicas son representadas mediante diagramas de dispersión, gráficos x-y (R^2), en que observaciones se representan en eje de ordenadas y variable temporal en eje de abscisas. Variable tiempo (t) es la variable independiente, tomará valores enteros positivos. Variable observaciones (y), dependiente del tiempo: $Y_0, Y_1, Y_2, Y_3, Y_4, \dots, Y_n$. En análisis, se aplicarán métodos tradicionales de inferencia estadística para modernizar datos y conocer su bondad de ajuste.

3.2. Componentes

3.2.1. Tendencia secular (T)

De los componentes que afectan a los valores individuales en

una serie cronológica, el más importante es la tendencia secular o llamada tendencia, entendida como movimiento característico decrecimiento o crecimiento a largo plazo de serie tal que la tendencia sólo puede determinar si se dispone de datos de serie en un periodo largo de años. La tendencia es dirección hacia arriba o abajo en la serie de datos a largo plazo.

Las fuerzas básicas que se producen o afectan la tendencia son cambios en población, inflación, cambio tecnológico, incremento de productividad y ciclos de vida de productos. La modelización de estos componentes usa modelos lineales, polinomial y otros. El método más simple y más ampliamente usado para describir la tendencia es la regresión lineal simple tal que las transformaciones que pueden hacerse hacia este modelo, pues si la tendencia puede ser lineal creciendo a una cantidad absoluta constante a lo largo del tiempo o puede ser exponencial creciendo a una tasa constante a lo largo del tiempo; alternativamente, la tendencia puede ajustarse a un polinomio u otro modelo más complejo. Por su naturaleza el análisis de la tendencia tiene implicaciones de planificación administrativa a largo plazo.

3.2.2. Variación estacional

El componente estacional de serie es un patrón de cambio que se repite regularmente en el tiempo. Este movimiento se completa en periodo de un año y repetirse de manera semejante año tras año a fin de considerarse un cambio estacional. Para identificar el componente estacional en una serie histórica es necesario recopilar datos para más de un período anual. Por

ejemplo, si considera registros de demanda de habitaciones en hoteles de sitios turísticos más visitados durante el año en meses vacacionales de regímenes escolares de costa y sierra se produce mayor demanda que resto de meses del año, así datos presentarán variaciones estacionales con una marcada tendencia aumentar durante el período señalados.

Mientras que la tendencia se utiliza para la planificación a largo plazo, el análisis de componente estacional de serie histórica tiene implicaciones a corto plazo más inmediatas. Las fluctuaciones estacionales se presentan típicamente en datos clasificados por meses o trimestres, que conduce a estimar un valor estacional por separado para cada mes o trimestre del año; generalmente, en la forma de índice.

3.2.3. Variación cíclica C

El componente cíclico es la fluctuación en forma de ondas o ciclos de más de un año de duración producido por cambios en condiciones económicas. Los componentes cíclicos se asemejan a estacionales en que son movimientos ondulatorios repetitivos, pero difieren en que movimientos son de duración más prolongada y son menos predecibles tanto en duración como amplitud.

El análisis del comportamiento cíclico es una importante en planificación a largo y medio plazo, pues permite prever periodos en que estas variaciones afectarán las actividades. Un ejemplo de variación cíclica se presenta en precio del petróleo en últimas décadas, pues ha tenido periodos largos de crecimiento

sostenido seguidos de periodos de fuerte caída.

3.2.4. Fluctuación irregular I

El componente irregular corresponde a fluctuaciones causadas por sucesos impredecibles o no periódicos. El componente irregular puede deberse a fenómenos como un clima poco usual, huelgas guerras elecciones y cambios en leyes o por los errores que se cometan al realizar las mediciones. El principal uso de series de tiempo es realización de pronósticos. Existe un conjunto de técnicas de pronósticos conocidas como métodos de atenuación de series, que son fáciles de implementar y no requieren de técnicas matemáticas sofisticadas.

3.3. Atenuación

Las técnicas de atenuación o suavizamiento se emplean para reducir irregularidades; es decir, las fluctuaciones aleatorias, en una serie de tiempo, que provee una visión más clara del comportamiento subyacente en serie de datos. En algunas series cronológicas la variación estacional es tan pronunciada que no permite apreciar la tendencia o ciclos, que son muy importantes para entender el proceso observado. El suavizamiento puede remover la estacionalidad y hace que fluctuaciones a largo plazo aparezcan más claras. Además, con frecuencia, el analista quiere actualizar pronósticos diaria, semanal o mensualmente de manera rápida, barata y sencilla. Esto se puede lograr mediante los métodos de suavizamiento de datos.

Las técnicas más comunes son el suavizamiento

por promedios móviles y exponencial.

Como el tipo de estacionalidad varía de serie a serie, así debe variar el tipo de suavizado empleado. Estas técnicas se basan en promedios ponderados de mediciones anteriores. La explicación consiste en que los valores pasados contienen información de lo que ocurrirá en el futuro. Debido a que los valores anteriores influyen fluctuaciones aleatorias, así como información relativa al patrón subyacente de la variable en estudio, se hace un intento de suavizar estos valores.

Estos métodos son apropiados cuando:

- a) Hay que realizar pronósticos de muchas series.
- b) Solamente se requieren pronósticos a corto plazo (hasta unos cuantos meses).
- c) Es aceptable una precisión razonable, más no exacta.
- d) Desde el punto de vista costo/beneficio, no se justifican procedimientos más complicados.

Con base en esto, se pueden enumerar brevemente las ventajas y desventajas de los métodos de pronóstico por suavizamiento:

Ventajas:

- a) Simplicidad, facilidad de comprensión.
- b) Precisión aceptable, pero de ninguna manera exactitud total, en una amplia variedad de aplicaciones.
- c) Fácil implementación informática.

Desventajas:

- a) Por lo general, requieren de un sistema hombre/maquina, con vigilancia manual y posibilidad de invalidación.
- b) No pronostican los puntos cruciales, cuando hay cambios bruscos en el patrón de los datos.
- c) Se aplican solo en los pronósticos a corto plazo.
- d) Pueden reaccionar excesivamente al azar, causando oscilaciones destructivas.

Pueden presentar problemas técnicos en la selección del modelo correcto y en la selección de constantes de suavizamiento.

3.3.1. Promedios móviles

Los datos históricos se pueden atenuar en muchas formas, pero siempre con el objetivo de usar datos disponibles para desarrollar un modelo de pronóstico para períodos futuros. El método más simple e intuitivo es usar el promedio simple, consistente en encontrar la media metica de todas las observaciones y usarlo para pronosticar el siguiente periodo:

En general, este método tiene una validez muy limitada, pues es aplicable cuando los datos presentan tendencia, estacionalidad u otros patrones sistemáticos. En muchos análisis, datos que presentan mayor interés son los más recientes, pues dan mayor

información del actual estado del proceso que datos que fueron tomados al inicio m $\sum_{t=1}^n Y_t$ esto se puede calcular el promedio para las c recientes.

$$Y_{t+1} = \frac{\sum_{t=1}^n Y_t}{n}$$

Estar disponible una nueva observación, se puede calcular el promedio para las observaciones más recientes. Estar disponible una nueva observación, se puede calcular una nueva media eliminando el valor antiguo e incluyendo el más reciente. Para describir este enfoque se emplea el término promedio, media, móvil. Entonces, se usa promedio móvil para pronosticar el siguiente periodo.

La expresión matemática de la media móvil es

,

Donde,

M_t : Promedio móvil en el periodo t

Y_{t+1} : Valor del pronóstico para el siguiente periodo

Y_t : Valor real en el periodo

n: Número de términos en el promedio móvil

$$M_t = Y_{t+1} = \frac{Y_t + Y_{t-1} + Y_{t-2} + \dots + Y_{t-n+1}}{n}$$

El pron aritmética de observaciones más recientes. Considere el número de períodos que intervienen en cálculo de una media móvil particular no cambia al correr del tiempo. Por esto, es importante escoger el número de períodos n, que se denomina su orden. Para datos trimestrales es frecuente que se utilice un promedio móvil de

orden 4 y para datos mensuales un promedio móvil de orden 12; es decir, se emplea el mismo orden de la estacionalidad de la serie.

3.3.2. Media móvil doble

Es una variante del método expuesto, tiene mayor efectividad cuando se dispone de una serie de tiempo cuya tendencia es lineal. Primero, el método consiste en calcular un conjunto de promedios móviles y, luego, se calcula un segundo conjunto como promedio móvil del primero. La técnica de atenuación por promedio móvil doble se realiza:

1. Se calcula el promedio móvil (simple) de datos:

2. Se usa esta nueva serie para calcular un segundo conjunto de promedios móviles:
 $(\alpha < 1)$

$$3. \quad M_t = \frac{Y_t + Y_{t-1} + Y_{t-2} + \dots + Y_{t-n+1}}{n} \quad \text{os móviles}$$

Un factor de ajuste adicional, similar a medición de una pendiente

$$M_t^I = \frac{M_t + M_{t-1} + M_{t-2} + \dots + M_{t-n+1}}{n}$$

4. Se forma la ecuación $\alpha_t = M_t - M_t^I$ para realizar el pronóstico en períodos futuros.

3.3.3 Exponencial

El suavizamiento exponencial es un método que se utiliza para revisar constantemente la estimación de los coeficientes de un modelo de pronóstico con base a cada observación si es real. El método se basa en promediar valores anteriores de una serie de forma decreciente asignando mayor peso a la más reciente. $\bar{y}_{t+p} = \alpha_t + b_{tp}$

Las ponderaciones empleadas designan como ($\alpha < 1$) para la observación más reciente, $\alpha (1 - \alpha)^2$ siguiente y sucesivamente.

El método de cálculo de los pronósticos es:

$$\text{Nuevo pronóstico} = \alpha \times (\text{nueva observación}) + (\text{pronóstico anterior})$$

Tal que la ecuación de atenuación exponencial es

Donde,

:Nueva valor atenuado o valor del pronóstico para el siguiente]

$$\bar{y}_{t+1} = \alpha Y_t + (1 - \alpha) \bar{y}_t,$$

α : constante de atenuación

\bar{Y}_t : Nueva observación o valor real en el periodo t-1

$$\bar{y}_{t+1}$$

Valor atenuado anterior o experiencia promedio de la serie o atenuada al periodo t,

Una mejor interpretación de la ecuación que define el suavizamiento exponencial se puede ver la siguiente imposición:

$$\bar{y}_t :$$

La atenuación exponencial es simplemente el pronóstico

anterior (\bar{y}_{t-1}) más veces el error ($\bar{y}_t - \bar{y}_{t-1}$) en el pronóstico anterior. La constante de suavizado sirve como el factor para $\bar{y}_{t+1} = \alpha Y_t + (1 - \alpha) \bar{y}_t = \alpha Y_t - \alpha \bar{Y} - \alpha \bar{y}_t$ hasta el cual la observación (\bar{y}_t) es el pronóstico.

Cuando es cercano en el nuevo pronóstico la observación más influyente será la más reciente. Inversamente cuando es cercano a 0, en el pronóstico influirán todas las observaciones de manera similar. Un método para estimar consiste en encontrar aquel valor que minimiza el error cuadrático medio (ECM) :

Para diferentes valores de α . Para generar pronósticos futuros se elige el valor que produce el error más pequeño. Finalmente, para definir cuál de dos pronósticos es el más aceptable, se puede comparar los errores cuadráticos medios de las series.

$$ECM = \sqrt{\frac{\sum_{t=1}^n (Y_t - \bar{y}_t)^2}{n}}$$

3.3.4. Exponencial doble

La técnica de suavizamiento exponencial doble, método de Brown, se emplea para pronosticar series que tienen una tendencia lineal y es semejante al atenuamiento por la media móvil doble. Primero, conviene que tener en cuenta que debido a valores de serie no son pronósticos en sí mismos, las ecuaciones de actualización son más comprensibles si se adopta $A_{(t)}$ como valor simple, suavizado exponencialmente de $Y_{(t)}$ en el periodo t, $A_{(t)}$ es valor doblemente suavizado exponencialmente de $Y_{-(t)}$ en periodo t. La técnica de suavizamiento exponencial doble se realiza:

a) Se calcula el valor simple suavizado exponencialmente:

b) Se calcula valor doblemente suavizado exponencialmente, realizando otro suavizamiento exponencial a datos obtenidos:

$$A_{(t)} + 1 = [\alpha y_{(t+1)}] + (1 - \alpha) A_{(t)}$$

c) Se estima la diferencia de valores atenuados

exponencialmente:

$$A_{(t+1)} = [\alpha A_{(t+1)}] + (1 - \alpha)A_{(t)}$$

Un factor de ajuste adicional es, similar a la pendiente:

$$A_{(t)} = 2A_{(t)} - \hat{A}_{(t)}$$

d) Se forma la ecuación para realizar el pronóstico de , periodos futuros:

$$3.3.5. \text{ Método } b_{(t)} = \left[\left(\frac{\alpha}{1-\alpha} \right) (A_{(t)} - \hat{A}_{(t)}) \right]$$

El método de Holt es una técnica que se emplea para manejar series de datos que tienen una tendencia lineal pero no presentan estacionalidad en forma directa. La tendencia es estimada en forma directa mediante constantes de suavizamiento para cada uno. Este método presenta mayor flexibilidad al seleccionar los métodos.

La técnica consiste en:

a) Se suaviza la serie mediante el método

b) Se estima la tendencia:

c) Se realiza el pronóstico de periodos futuros:

La predicción $T_{(t)} = \beta_{(t)}(A_{(t)} - A_{(t-1)}) + (1 - \beta_{(t)})T_{(t-1)}$ es una estimación de tendencia simple, con excepción de que incorpora el término $(T_{(t-1)} - T_{(t-2)})$ para la tendencia. En la segunda ecuación, se toman dos valores sucesivos exponencial, pues se atenuaron con fines de eliminar la aleatoriedad, su diferencia constituye una estimación de tendencia local de datos.

Se atenúa esta tendencia con la constante $\beta_{(t)}$ (Constante de atenuación para la estimación de la tendencia $(0 < \beta < 1)$) y se suma tendencia anterior multiplicada por $1 - \beta_{(t)}$ (Constante de atenuación para la estimación de la tendencia $(0 < \beta < 1)$).

El valor obtenido es una tendencia atenuada que excluye cualquier aleatoriedad. La ecuación del pronóstico suma el nivel actual de datos $A_{(t)}$ (Nuevo valor atenuado) y el producto de la tendencia t por p periodos.

Note que, para iniciar la interacción, se toma $A_1 = Y_1$ y $T_1 = 0$

3.3.6. Método de Winters

La atenuación por método de Winters es apropiada cuando la serie presenta una tendencia lineal y una variación estacional.

Es una extensión del modelo de Holt, usa una ecuación adicional

para estimar la estacionalidad mediante un índice estacional.
Sus pasos de cálculo son:

a) Se suaviza la serie exponencialmente

b) Se estima la tendencia:

$$c) \text{ Se estima } A_{(t)} = (\alpha) \left(\frac{Y_{(t)}}{S_{(t)} - 1} \right) + [(1 - \alpha)(A_{(t-1)} + T_{(t-1)})]$$

$$d) \text{ Se realiza } T_{(t)} = [\beta(A_{(t)} - A_{(t-1)})] + [(1 - \beta)T_{(t-1)}]$$

Obsérvese que $S_{(t)} = \left[(r) \left(\frac{Y_{(t)}}{A_{(t)}} \right) \right] + [(1 - r)S_{(t-L)}]$ se calcula tomando en cuenta el índice estacional $S_{(t-L)}$ (Longitud de la estacionalidad), correspondiente a L (Longitud de la estacionalidad) períodos anteriores y p y $A_1 = Y_1, T_1 = 0$ y $s_k = 1$ cuando $\hat{y}_{(y+p)} = (A_{(t)} + T_{(t)p})S_{(t-L+p)}$

3.4. Comparación de métodos

No existe un método que sea el mejor en toda ocasión. Su elección dependerá del conjunto de datos que se disponga y finalidad de estos. La comparación de técnicas de atenuación se

hace mediante el error cuadrático medio:

Donde es error de pronóstico para cada una de las observaciones de serie. Entonces, el método que proporcione el menor será el más apropiado para la serie de tiempo que se analiza. El siguiente cuadro resume métodos analizados con su :

$$ECM = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} = \sqrt{\frac{\sum_{t=1}^n e_i^2}{n}}$$

Tabla 6. Comparación de métodos

Método	Parámetros
ECM (Error cuadrático medio)	
Combase en resultados, el mejor método es el promedio móvil simple y el pronóstico basado en el sería apropiado. Dependiendo de las observaciones se sugiere que se use modelo exponencial, si serie no tiene una tendencia marcada y no muestra variación estacional.	34.824.8
Suavizamiento exponencial $\alpha = 0.1$	27.902.7
Suavizamiento exponencial $\alpha = 0.6$	33.991.3
Suavizamiento exponencial doble $\alpha = 0.1$	29.547.4
Holt, si serie tiene tendencia lineal pero no muestra estacionalidad.	35.044
Modelo de Winters	54.548.9

Para cada constante de atenuación, cuanto mayor sea su valor mayor importancia se dará a observación más reciente.

La mayoría de programas estadísticos que disponen de estos métodos tienen implementados algoritmos que escogen automáticamente la combinación de parámetros que dan $ECM_{(Error\ cuadrático\ medio)}$ mínimo, permite tener una estimación apropiada a observaciones disponibles. Es recomendable implementar fórmulas de diversos métodos en una hoja electrónica para estimación de cálculos.

Como el objetivo del ejemplo es ilustrar el funcionamiento de las técnicas, los valores de los parámetros de suavizamiento se tomaron de manera arbitraria; ellos no son los óptimos para ninguno de los métodos.

3.5. Ejercicios

1. En una academia de idiomas se sigue un sistema trimestral. El número de alumnos que estudian idiomas en cada trimestre, durante 4 años, se resume en la siguiente tabla:

Tabla 7. Número de alumnos que estudian idiomas en cada trimestre, durante 4 años

Año	Tri-mestre	No. Alum-nos	Año	Trimes-tre	No. Alumnos
1	1	10	3	1	13
	2	31		2	34
	3	43		3	48
	4	16		4	19
2	1	11	4	1	15
	2	33		2	37

Año	Tri-mestre	No. Alum-nos	Año	Trimes-tre	No. Alumnos
	3	45		3	51
	4	17		4	21

Mediante métodos que se indican, realice suavizamiento de la serie y el pronóstico al periodo señalado. También, calcule su $ECM_{(Error\ cuadrático\ medio)}$.

- a) Grafique los datos;
- b) Promedios móviles de orden 4 y $\rho=1$
- c) Media móvil doble de orden 4 y $\rho=1$;
- d) Suavizamiento exponencial con $\alpha=0.2$ y $\rho=1$;
- e) Suavizamiento exponencial doble con $\alpha=0.2$ y $\rho=1$;
- f) Método de Holt con $\alpha=0.2$, $\beta=0.3$;
- g) Método de Winters para cuatro trimestres, con $\alpha=0.1$, $\beta=0.3$ y $\gamma=0.4$

2. Ventas trimestrales de casas que ha realizado una compañía inmobiliaria en los últimos años se representa:

Tabla 8. Ventas trimestrales de casas que ha realizado una compañía inmobiliaria en los últimos años

Año	Trimestre	Ventas	Año	Trimestre	Ventas
1	1	50	4	1	55
	2	35		2	35
	3	25		3	25
	4	40		4	55

Año	Trimestre	Ventas	Año	Trimestre	Ventas
2	1	45	5	1	55
	2	35		2	40
	3	20		3	35
	4	30		4	60
3	1	35	6	1	75
	2	20		2	50
	3	15		3	40
	4	40		4	65

a) Grafique los datos;

Mediante métodos que se indican, realicen el suavizado de la serie y pronóstico al periodo señalado.

- a) Promedios móviles de orden 4 y 1;
- b) Media móvil doble de orden 4 y 1;
- c) Suavizado exponencial con $\alpha=0.1$ y $\rho=1$;
- d) Suavizado exponencial doble con $\alpha=0.3$
- e) Método de Holt con $\alpha=0.1$, $\beta=0.25$;
- f) Método de Winters para cuatro trimestres, con $\alpha=0.4$, $\beta=0.1$ y $\gamma=0.3$;

g) Halle el mejor método de ajuste mediante $ECM_{(\text{Error cuadrático medio})}$.

3. En una universidad se implantó el sistema de estudios cuatrimestral. El número de alumnos matriculados en la materia de geometría se presenta a continuación:

Tabla 9. Número de alumnos matriculados en la materia de geometría

Periodo	Alumnos	Periodo	Alumnos
1	54	9	101
2	58	10	103
3	65	11	102
4	72	12	110
5	73	13	112
6	71	14	111
7	93	15	128
8	94		

Grafique los datos;

Mediante métodos que se indican, realice el suavizado de la serie y el pronóstico al periodo señalado.

- a) Promedios móviles de orden 3 y 1;
- b) Media móvil doble de orden 3 y 1;
- c) Suavizado exponencial con $\alpha=0.4$ y $\rho=1$; Suavizado exponencial doble con $\alpha=0.4$ y $\rho=1$;
- d) Método de Holt con $\alpha=0.4$ y $\rho=1$;
- e) Método de Winters para tres trimestres, con $\alpha=0.2$, $\beta=0.15$ y $\gamma=0.1$

Halle el mejor método de ajustes mediante el criterio $ECM_{(\text{Error cuadrático medio})}$.

$$= b^2 + d^2 = 5x$$

$$\overline{b(d^2) + d^5}$$

$$5x^2 + d^4$$

$$2(5ad)$$



4. Archivo de comando o script

4.1. Para instalar un conjunto de comandos con que R crea herramienta para generación de informes dinámico en R

install.packages("knitr") # Archivo de comando o script que permite instalar un conjunto de comandos con que R crea herramienta para generación de informes dinámico en R. Es un paquete en el lenguaje de programación estadístico R que permite integrar R en documentos LaTeX, LyX, HTML, Markdown, AsciiDoc, y reStructuredText.

El propósito de knitr es dar espacio a la reproducibilidad de investigación en R a través de Programación Literaria. Si desea desinstalar un paquete es con script detach(package:"nombre.de.paquete") o remove.packages("nombre.de.paquete"). Si requiere actualizar paquetes se usa script update.packages().

También, se puede hacer mediante:

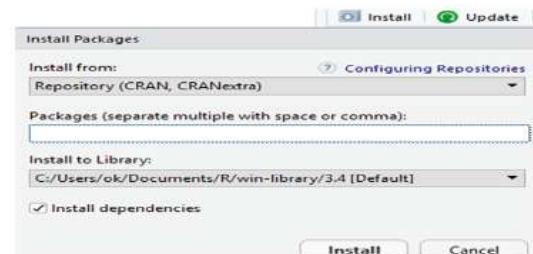


Figura 2. Comando o script que permite instalar un conjunto de comandos con que trabaja R. Opción A

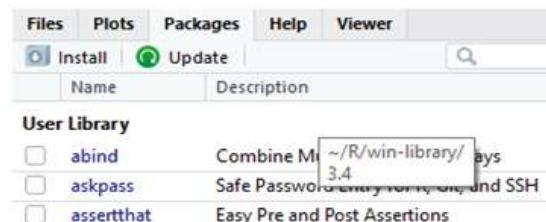


Figura 4. Comando o script que permite instalar un conjunto de comandos con que trabaja R. Opción B



Figura 5. Comando o script que permite instalar un conjunto de comandos con que trabaja R. Opción C

install.packages("plotly") # Una variedad de gráficas responsivas, interactivas y ricas en funcionalidad. Por ejemplo: barras, sectores, dispersión, histograma, serie temporal, pastel, caja o box plot, dispersión, mosaico, densidad, etcétera. Estos gráficos pueden guardarse en diferentes formatos:

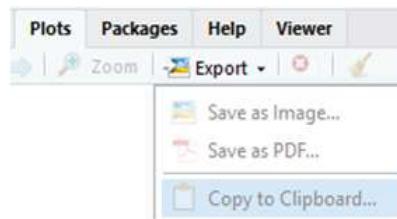


Figura 5. Comando o script que permite instalar un conjunto de comandos con que trabaja R. Opción C

4.2. Para instalar un conjunto de comandos con que R crea presentaciones en power point, libros, artículos u otros textos

```
install.packages("shiny") # Archivo de comando o script que permite instalar un conjunto de comandos con que R crea presentaciones en power point, libros, artículos u otros textos
```

```
install.packages("Lock5Data")
```

```
install.packages("plotrix")
```

```
install.packages("ggplot2")
```

```
install.packages("scatterplot3d")
```

```
install.packages("highcharter")
```

```
install.packages("tmap")
```

```
install.packages("leaflet")
```

```
install.packages("rpivotTable")
```

```
install.packages("collapsibleTree")
```

```
install.packages("readxl", dependencies = TRUE) # Archivo de
```

comando o script que permite instalar un conjunto de comandos que importan información creada en Excel (data frame) con terminación xl hacia R

```
install.packages("csv", dependencies = TRUE) # Archivo de comando o script que permite instalar un conjunto de comandos que importan información creada en Excel (data frame) con terminación csv hacia R
```

```
install.packages("foreign", dependencies = TRUE) # Archivo de comando o script que permite instalar un conjunto de comandos que importan información creada en otros softwares o paquetes informáticos hacia R
```

```
install.packages("haven", dependencies = TRUE)
```

```
install.packages("R.matlab", dependencies = TRUE) # Archivo de comando o script que permite instalar un conjunto de comandos que importan información creada (data frame) en software Matlab hacia R
```

```
install.packages("data.table")
```

4.3. Para instalar un conjunto de comandos que permite usar memoria de disco duro en memoria RAM de la PC tal que facilita cálculos y uso óptimo de la computadora en R

```
install.packages("bigmemory") # Archivo de comando o script que permite instalar un conjunto de comandos que permite usar memoria de disco duro en memoria RAM de la PC tal que
```

facilita cálculos y uso óptimo de la computadora en R

```
install.packages("tinytex")
```

```
install.packages("carData")
```

```
install.packages("car")
```

```
install.packages("moments")
```

```
install.packages("nortest")
```

```
install.packages("Jhonson")
```

```
install.packages("mvnormtest")
```

```
install.packages("MVN")
```

```
install.packages("lpSolve")
```

```
install.packages("boot")
```

```
install.packages("lmtest") # Pruebas de violación de autocorrelación durbinWatsonTest tal que si no se cumple tampoco son válidas las pruebas estadísticas del modelo de regresión, pues coeficientes de regresión no tendrán varianza mínima (errores estándar)
```

```
install.packages("orcutt") # Prueba de corrección de
```

autocorrelación de 1er orden Cochrane-Orcutt

install.packages("lawstat") # Archivo de comando o script que permite instalar la prueba de homocedasticidad de Levene

install.packages("outliers") # Archivo de comando o script que permite instalar la prueba de homocedasticidad de Cochran

4.4. Para cargar un conjunto de comandos con que trabaja R

library(knitr) # Archivo de comando o script que permite cargar un conjunto de comandos con que trabaja R

library(plotly)

library(shiny)

library(Lock5Data)

library(plotrix)

library(ggplot2)

library(scatterplot3d)

library(highcharter)

library(tmap)

library(leaflet)

library(rpivotTable)

library(collapsibleTree)

library(readxl)

library(csv)

library(foreign)

library(haven)

library(R.matlab)

library(data.table)

library(bigmemory)

library(tinytex)

library(carData)

library(car)

library(moments)

library(nortest)

```
library(Jhonson)
```

```
library(mvnormtest)
```

```
library(MVN)
```

```
library(lpSolve)
```

```
library(boot)
```

```
library(lmtest)
```

```
library(orcutt)
```

```
library(lawstat)
```

```
library(outliers)
```

4.5. Ejercicios de aplicación

4.5.1. Ejemplo 1. “Arroz.Nacional”

`getwd()` # Según diccionario de real academia española (RAE) es acrónimo, sigla cuya configuración permite su pronunciación como una palabra en este caso inglés, de get working directory (`getwd`). En este caso, el directorio de trabajo puede ser “C:/Users/ok/Documents”

```
library(readxl)
```

```
Arroz_Nacional <- read_excel("E:/Libros para Ingeniería/
```

Regresión lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/Arroz.Nacional.xlsx”)

`View(Arroz_Nacional)` # Archivo de comando o script que permite visualizar el base datos tabulada, en tablas o matriz que se cargó con script `read_excel("Ejemplo1.xlsx", sheet = "Base", col_names = TRUE, na=c(""))`. El archivo de comando o script también se puede obtener mediante (margen superior izquierdo de cuadro):

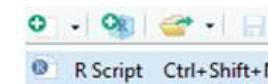


Figura 5. Comando o script que permite visualizar el base datos tabulada, en tablas o matriz.

Opción A

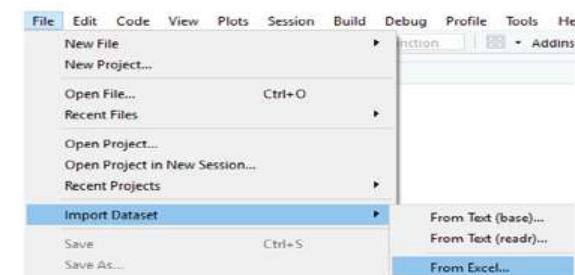


Figura 5. Comando o script que permite visualizar el base datos tabulada, en tablas o matriz.

Opción B (mediante barra de menú)

```
str(Arroz_Nacional) # Archivo de comando o script (string)
que permite ver la cadena de caracteres, como tipo de variable,
número de elementos, encabezados, etcétera
```

```
names(Arroz_Nacional) # Archivo de comando o script (names)
que permite ver los nombres de variables de base de datos
```

```
cor(Arroz_Nacional) # Archivo comando o Script que da
coeficiente de correlación entre variables de interés
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Semilla_
comun + Semilla_mejorada + Semilla_certificada + Semilla_
HN + Semilla_HI + Riego + Superficie_cosechada + Sequia +
Helada + Plagas + Enfermedades + Inundacion + Otras_causas
+ Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios +
Ventas + Precios_Prod_Pond.Ene + Precios_Prod_Pond_Feb +
Precios_Prod_Pond_Mar + Precios_Prod_Pond_Abr + Precios_
Prod_Pond_May + Precios_Prod_Pond_Jun + Precios_Prod_
Pond_Jul + Precios_Prod_Pond_Ago + Precios_Prod_Pond_
Sep + Precios_Prod_Pond_Oct + Precios_Prod_Pond_Nov +
Precios_Prod_Pond_Dic + Precios_Bod_Comer_Ene + +
Precios_Bod_Comer_Feb + Precios_Bod_Comer_Mar + +
Precios.Bod.Comer.Abr + Precios.Bod.Comer.May + Precios.
Bod.Comer.Jun + Precios_Bod_Comer_Jul + Precios_Bod_
Comer_Ago + Precios_Bod_Comer_Sep + Precios_Bod_
Comer_Oct + Precios_Bod_Comer_Nov + Precios_Bod_
Comer_Dic + Precios_Bod_Comer_Pil_Ene + Precios_Bod_
Comer_Pil_Feb + Precios_Bod_Comer_Pil_Mar + Precios_
Bod_Comer_Pil_Abr + Precios_Bod_Comer_Pil_May +
```

```
Precios_Bod_Comer_Pil_Jun + Precios_Bod_Comer_Pil_Jul +
Precios_Bod_Comer_Pil_Ago + Precios_Bod_Comer_Pil_Sep
+ Precios_Bod_Comer_Pil_Oct + Precios_Bod_Comer_Pil_
Nov + Precios_Bod_Comer_Pil_Dic + Fosfato_diam_Fert_Ene
+ Fosfato_diam_Fert_Feb + Fosfato_diam_Fert_Mar +
Fosfato_diam_Fert_Abr + Fosfato_diam_Fert_May + Fosfato_
diam_Fert_Jun + Fosfato_diam_Fert_Jul + Fosfato_diam_
Fert_Ago + Fosfato_diam_Fert_Sep + Fosfato_diam_Fert_Oct
+ Fosfato_diam_Fert_Nov + Fosfato_diam_Fert_Dic +
Muriato_K_Fert_Ene + Muriato_K_Fert_Feb + Muriato_K_
Fert_Mar + Muriato_K_Fert_Abr + Muriato_K_Fert_May +
Muriato_K_Fert_Jun + Muriato_K_Fert_Jul + Muriato_K_
Fert_Ago + Muriato_K_Fert_Sep + Muriato_K_Fert_Oct +
Muriato_K_Fert_Nov + Muriato_K_Fert_Dic + Urea_Fert_Ene
+ Urea_Fert_Feb + Urea_Fert_Mar + Urea_Fert_Abr + Urea_
Fert_May + Urea_Fert_Jun + Urea_Fert_Jul + Urea_Fert_Ago
+ Urea_Fert_Sep + Urea_Fert_Oct + Urea_Fert_Nov + Urea_
Fert_Dic + Propiconazol_Fungi_Ene + Propiconazol_Fungi_
Feb + Propiconazol_Fungi_Mar + Propiconazol_Fungi_Abr +
Propiconazol_Fungi_May + Propiconazol_Fungi_Jun +
Propiconazol_Fungi_Jul + Propiconazol_Fungi_Ago +
Propiconazol_Fungi_Sep + Propiconazol_Fungi_Oct +
Propiconazol_Fungi_Nov + Propiconazol_Fungi_Dic + Cimo_
Manco_Fungi_Ene + Cimo_Manco_Fungi_Feb + Cimo_
Manco_Fungi_Mar + Cimo_Manco_Fungi_Abr + Cimo_
Manco_Fungi_May + Cimo_Manco_Fungi_Jun + Cimo_
Manco_Fungi_Jul + Cimo_Manco_Fungi_Ago + Cimo_
Manco_Fungi_Sep + Cimo_Manco_Fungi_Oct + Cimo_
Manco_Fungi_Nov + Cimo_Manco_Fungi_Dic +
```

Carbendazim_Fungi_Ene	+	Carbendazim_Fungi_Feb	+
Carbendazim_Fungi_Mar	+	Carbendazim_Fungi_Abr	+
Carbendazim_Fungi_May	+	Carbendazim_Fungi_Jun	+
Carbendazim_Fungi_Jul	+	Carbendazim_Fungi_Ago	+
Carbendazim_Fungi_Sep	+	Carbendazim_Fungi_Oct	+
Carbendazim_Fungi_Nov	+	Carbendazim_Fungi_Dic	+
Clorotalonil_Fungi_Ene	+	Clorotalonil_Fungi_Feb	+
Clorotalonil_Fungi_Mar	+	Clorotalonil_Fungi_Abr	+
Clorotalonil_Fungi_May	+	Clorotalonil_Fungi_Jun	+
Clorotalonil_Fungi_Jul	+	Clorotalonil_Fungi_Ago	+
Clorotalonil_Fungi_Sep	+	Clorotalonil_Fungi_Oct	+
Clorotalonil_Fungi_Nov	+	Clorotalonil_Fungi_Dic	+
Glifosato_Herbi_Ene	+	Glifosato_Herbi_Feb	+
Herbi_Mar	+	Glifosato_Herbi_Abr	+
Glifosato_Herbi_May	+	Glifosato_Herbi_Jun	+
Glifosato_Herbi_Jul	+	Glifosato_Herbi_Ago	+
Glifosato_Herbi_Sep	+	Glifosato_Herbi_Oct	+
Glifosato_Herbi_Nov	+	Glifosato_Herbi_Dic	+
Paraquat_Herbi_Ene	+	Paraquat_Herbi_Feb	+
Paraquat_Herbi_Mar	+	Paraquat_Herbi_Abr	+
Paraquat_Herbi_May	+	Paraquat_Herbi_Jun	+
Paraquat_Herbi_Jul	+	Paraquat_Herbi_Ago	+
Paraquat_Herbi_Sep	+	Paraquat_Herbi_Oct	+
Paraquat_Herbi_Nov	+	Paraquat_Herbi_Dic	+
Pendimetalina_Herbi_Ene	+	Pendimetalina_Herbi_Feb	+
Pendimetalina_Herbi_Feb	+	Pendimetalina_Herbi_Mar	+
Pendimetalina_Herbi_Abr	+	Pendimetalina_Herbi_May	+
Pendimetalina_Herbi_Jun	+	Pendimetalina_Herbi_Jul	+
Pendimetalina_Herbi_Ago	+	Pendimetalina_Herbi_Sep	+
Pendimetalina_Herbi_Oct	+	Pendimetalina_Herbi_Nov	+
Pendimetalina_Herbi_Dic	+	Propanil_Herbi_Ene	+
Propanil_Herbi_Feb	+	Propanil_Herbi_Mar	+
Propanil_Herbi_Abr	+	Propanil_Herbi_Jun	+

Agro_Mar + Credito_Agro_Abr + Credito_Agro_May +
 Credito_Agro_Jun + Credito_Agro_Jul + Credito_Agro_Ago +
 Credito_Agro_Sep + Credito_Agro_Oct + Credito_Agro_Nov
 + Credito_Agro_Dic + Empl_Tot_ITrim + Empl_Tot_IITrim +
 Empl_Tot_IIITrim + Empl_Tot_IVTrim + Empl_Agrop_ITrim
 + Empl_Agrop_IITrim + Empl_Agrop_IIITrim + Empl_Agrop_IVTrim +
 Tasa_empl_adec_Rural_ITrim + Tasa_empl_adec_Rural_IITrim +
 Tasa_empl_adec_Rural_IIITrim + Tasa_empl_adec_Rural_IVTrim +
 Tasa_sub_empl_adec_Rural_I + Tasa_sub_empl_adec_Rural_T +
 Tasa_sub_empl_adec_Rural_r + Tasa_sub_empl_adec_Rural_i +
 Tasa_sub_empl_adec_Rural_m + Tasa_sub_empl_adec_Rural_II +
 Tasa_sub_empl_adec_Rural_III + Tasa_sub_empl_adec_Rural_IV +
 Tasa_otro_empl_no_pleno_Rural_ITrim + Tasa_otro_empl_no_pleno_Rural_II +
 Tasa_otro_empl_no_pleno_Rural_III + Tasa_otro_empl_no_pleno_Rural_IV +
 Tasa_otro_empl_no_pleno_Rural_I + Tasa_otro_empl_no_pleno_Rural_T +
 Tasa_otro_empl_no_pleno_Rural_r + Tasa_otro_empl_no_pleno_Rural_i +
 Tasa_otro_empl_no_pleno_Rural_m + Tasa_empl_no_remun_Rural_ITrim +
 Tasa_empl_no_remun_Rural_II + Tasa_empl_no_remun_Rural_III +
 Tasa_empl_no_remun_Rural_IV + Tasa_desem_adecuado_Rural_ITrim +
 Tasa_desem_adecuado_Rural_II + Tasa_desem_adecuado_Rural_III +
 Tasa_desem_adecuado_Rural_IV + Pob_ingresos_Rural_ISem +
 Pob_ingresos_Rural_I + Pob_extrem_ingresos_Rural_ISem +
 Pob_extrem_ingresos_Rural_II + IPA + TPA + TPIAR + TVAA + IPP_N_Ene +
 IPP_N_Feb + IPP_N_Mar + IPP_N_Abr + IPP_N_May +
 IPP_N_Jun + IPP_N_Jul + IPP_N_Ago + IPP_N_Sep +
 IPP_N_Oct + IPP_N_Nov + IPP_N_Dic + IPP_X_Ene +
 IPP_X_Feb + IPP_X_Mar + IPP_X_Abr + IPP_X_May +

IPP_X_Jun + IPP_X_Jul + IPP_X_Ago + IPP_X_Sep +
 IPP_X_Oct + IPP_X_Nov + IPP_X_Dic + IPM_Ene + IPM_Feb +
 IPM_Mar + IPM_Abr + IPM_May + IPM_Jun + IPM_Jul +
 IPM_Ago + IPM_Sep + IPM_Oct + IPM_Nov + IPM_Dic +
 IPX_Ene + IPX_Feb + IPX_Mar + IPX_Abr + IPX_May +
 IPX_Jun + IPX_Jul + IPX_Ago + IPX_Sep + IPX_Oct + IPX_Nov +
 IPX_Dic + IPI_Ene + IPI_Feb + IPI_Mar + IPI_Abr +
 IPI_May + IPI_Jun + IPI_Jul + IPI_Ago + IPI_Sep + IPI_Oct +
 IPI_Nov + IPI_Dic + IPF_Ene + IPF_Feb + IPF_Mar + IPF_Abr +
 IPF_May + IPF_Jun + IPF_Jul + IPF_Ago + IPF_Sep +
 IPF_Oct + IPF_Nov + IPF_Dic + IBC_Ene + IBC_Feb + IBC_Mar +
 IBC_Abr + IBC_May + IBC_Jun + IBC_Jul + IBC_Ago +
 IBC_Sep + IBC_Oct + IBC_Nov + IBC_Dic + IPCA_Ene +
 IPCA_Feb + IPCA_Mar + IPCA_Abr + IPCA_May + IPCA_Jun +
 IPCA_Jul + IPCA_Ago + IPCA_Sep + IPCA_Oct +
 IPCA_Nov + IPCA_Dic + Inf_Men_Ene + Inf_Men_Feb +
 Inf_Men_Mar + Inf_Men_Abr + Inf_Men_May + Inf_Men_Jun +
 Inf_Men_Jul + Inf_Men_Ago + Inf_Men_Sep + Inf_Men_Oct +
 Inf_Men_Nov + Inf_Men_Dic + Precipit_Ene +
 Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May +
 Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep +
 Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_Ene +
 Temp_Feb + Temp_Mar + Temp_Abr + Temp_May + Temp_Jun +
 Temp_Jul + Temp_Ago + Temp_Sep + Temp_Oct +
 Temp_Nov + Temp_Dic, data = Arroz_Nacional)

summary(modelo) # Archivo comando o Script que genera cuadro de Análisis de Varianza para evaluación del modelo lineal general, en inglés general linear model

```
ANOVA <- aov(modelo) # Archivo comando o Script que genera cuadro de Análisis de Varianza para evaluación del modelo lineal general, en inglés general linear model
```

```
summary(ANOVA)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004", "2005", "2006", "2007", "2008", "2009", "2010", "2011", "2012", "2013", "2014", "2015", "2016", "2017", "2018", "2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(1246634, 1339723, 1432811, 1384715, 1778380, 1471064, 1501238, 1734135, 1442052, 1579406, 1706193, 1477941, 1565535, 1516045, 1379954, 1652793, 1534537, 1066614, 1772929, 1246634, 1246634)
```

```
Semilla_comun <- c(230548, 260203, 289858, 292396, 289024, 276999, 267713, 254496, 181359, 253128, 223626, 197911, 212766, 187056, 160397, 124302, 148923, 165986, 230548, 230548, 230548)
```

```
Semilla_HN <- c(0, 0, 0, 0, 0, 520, 1343, 3015, 712, 1292, 522, 188, 319, 2938, 194, 294, 0, 0, 0, 0)
```

```
Riego <- c(153882, 143799, 133716, 150522, 2 0 5 0 5 2 ,
```

```
202875, 209051, 23904, 172474, 242153, 202998, 247262, 260827, 270142, 239268, 278565, 267027, 234385, 153882, 153882, 153882)
```

```
Superficie_cosechada <- c(338653, 354226, 369798, 357564, 421548, 377300, 357558, 398151, 354841, 394813, 393137, 329957, 371170, 396770, 354136, 375117, 366194, 358100, 315976, 338653, 338653)
```

```
Sequia <- c(2906, 1625, 344, 8706, 9031, 21357, 7723, 4534, 884, 15706, 2139, 24434, 2628, 1127, 3223, 4803, 3009, 738, 2906, 2906, 2906)
```

```
Helada <- c(0, 0, 0, 0, 77, 91, 0, 78, 239, 290, 319, 529, 162, 568, 0, 38, 189, 22, 0, 0, 0)
```

```
Plagas <- c(1621, 1287, 952, 565, 1674, 1287, 1750, 1866, 2386, 2596, 7216, 14922, 12777, 10477, 11054, 9944, 10146, 3810, 1621, 1621, 1621)
```

```
Enfermedades <- c(363, 182, 0, 0, 102, 361, 0, 51, 443, 172, 867, 777, 732, 211, 377, 675, 409, 225, 363, 363, 363)
```

```
Inundacion <- c(3013, 3156, 3298, 217, 413, 3601, 8756, 2899, 21241, 3235, 6407, 3255, 22798, 2277, 6451, 6037, 3796, 6953, 3013, 3013, 3013)
```

```
Aplicacion_Fertilizantes <- c(318634, 336499, 354364, 346012, 416416, 388843, 364667, 398088, 369594, 413266,
```

```
403758, 367487, 404429, 390422, 365924, 395709, 380171,
367659, 318634, 318634, 318634)
```

```
Aplicacion_Fitosanitarios <- c(302845, 326103, 349360,
340423, 414271, 392305, 361726, 400673, 366303, 409238,
400771, 359682, 405619, 368376, 363324, 392839, 380072,
366836, 302845, 302845, 302845)
```

```
Ventas <- c(1104669, 1168449, 1232229, 1218461, 1585790,
1325886, 1372606, 1568338, 1258282, 1451784, 1548537,
1299403, 1416965, 1431552, 1282065, 1534476, 1432318,
1017087, 1104669, 1104669, 1104669)
```

```
Credito_Agro_Mar <- c(0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
-4633605, -2218799, 196007, 3385244, 3476755, 8214856,
9855229, 12270035)
```

```
Precipit_Ene <- c(147, 602, 113, 257, 124, 63, 360, 275, 489,
491, 221, 271, 304, 306, 413, 187, 328, 332, 337, 341, 346)
```

```
Precipit_Feb <- c(351, 426, 539, 377, 291, 109, 665, 221, 604,
339, 535, 329, 493, 786, 421, 104, 434, 437, 439, 442, 445)
```

```
Precipit_Mar <- c(551, 475, 658, 297, 384, 348, 353, 452, 563,
226, 332, 140, 588, 339, 90, 453, 317, 303, 289, 276, 262)
```

```
Precipit_Abr <- c(254, 371, 527, 288, 317, 411, 72, 298, 462,
76, 370, 417, 274, 250, 85, 587, 301, 299, 298, 296, 294)
```

```
Precipit_May <- c(109, 34, 99, 55, 147, 1, 25, 57, 116, 79, 113,
2, 191, 307, 423, 173, 96, 99, 101, 104, 106)
```

```
Precipit_Jun <- c(9.27, 0.10, 5.47, 12.23, 10.13, 0.00, 13.07,
15.53, 2.67, 14.57, 8.27, 36.17, 36.85, 3.90, 7.50, 159.60, 55.59,
59.67, 63.74, 67.82, 71.89)
```

```
Precipit_Jul <- c(0.13, 1.87, 1.67, 5.20, 1.73, 0.70, 0.37, 2.10,
0.37, 0.00, 9.53, 61.10, 1.15, 6.68, 12.20, 18.79, 20.53, 22.27,
24.02, 25.76, 27.50)
```

```
Precipit_Ago <- c(0.17, 0.20, 0.10, 6.70, 0.00, 0.03, 1.13, 0.23,
7.63, 0.00, 0.43, 0.30, 0.00, 1.40, 2.80, 1.16, 1.14, 1.11, 1.09,
1.07, 1.05)
```

```
Precipit_Sep <- c(3.90, 0.17, 0.13, 0.13, 11.90, 0.00, 0.60, 0.00,
3.17, 0.00, 1.67, 1.37, 1.15, 0.00, 1.70, 0.74, 0.62, 0.49, 0.37,
0.25, 0.12)
```

```
Precipit_Oct <- c(0.00, 0.43, 7.63, 5.73, 6.60, 0.63, 0.40, 1.50,
7.53, 4.10, 2.53, 1.13, 1.35, 9.10, 31.20, 11.68, 12.48, 13.27,
14.06, 14.86, 15.65)
```

```
Precipit_Nov <- c(0.00, 0.60, 3.27, 57.40, 8.45, 0.50, 8.53,
8.90, 3.77, 0.20, 4.97, 3.43, 4.95, 0.00, 0.00, 0.52, 0.00, 0.00,
0.00, 0.00, 0.00)
```

```
Precipit_Dic <- c(35.17, 15.43, 100.63, 45.57, 13.60, 135.93,
66.13, 86.97, 15.77, 99.33, 321.33, 81.03, 23.55, 30.40,
```

5.90, 84.38, 85.96, 87.53, 89.11, 90.68, 92.26)

Temp_Ene <- c(25.87, 26.00, 27.07, 26.60, 27.40, 27.57, 26.87, 26.73, 24.93, 26.37, 26.60, 25.70, 25.43, 26.15, 16.55, 26.40, 25.92, 25.85, 25.79, 25.73, 25.67)

Temp_Feb <- c(25.97, 26.63, 26.33, 26.77, 26.85, 26.57, 26.67, 27.33, 26.10, 26.30, 27.03, 26.20, 26.45, 27.10, 27.20, 26.00, 26.71, 26.72, 26.73, 26.74, 26.76)

Temp_Mar <- c(26.67, 27.10, 27.27, 27.23, 27.05, 26.83, 27.60, 27.20, 26.87, 26.90, 27.33, 27.33, 27.25, 27.58, 27.90, 26.90, 27.28, 27.30, 27.32, 27.34, 27.36)

Temp_Abr <- c(26.80, 27.13, 27.03, 27.47, 27.05, 27.40, 27.30, 27.30, 27.27, 27.27, 27.47, 26.73, 27.50, 26.80, 27.10, 27.19, 27.19, 27.19, 27.19, 27.19, 27.20)

Temp_May <- c(25.77, 25.77, 26.93, 26.67, 26.45, 26.00, 26.53, 26.40, 25.93, 26.67, 27.03, 26.57, 27.30, 27.30, 27.30, 27.50, 26.96, 27.03, 27.10, 27.18, 27.25)

Temp_Jun <- c(24.63, 24.30, 25.47, 24.90, 24.87, 25.40, 25.33, 25.30, 25.37, 25.53, 25.33, 25.70, 26.50, 26.70, 26.90, 27.60, 26.07, 26.18, 26.29, 26.40, 26.52)

Temp_Jul <- c(23.63, 24.03, 25.03, 24.53, 24.27, 24.67, 24.73, 25.13, 25.13, 25.20, 25.00, 25.00, 25.45, 25.68, 25.90, 25.52, 25.63, 25.73, 25.84, 25.95, 26.06)

Temp_Ago <- c(24.23, 23.77, 24.37, 24.90, 24.80, 24.40, 25.20, 24.00, 25.00, 25.30, 24.77, 24.43, 24.95, 25.43, 25.90, 27.60, 25.03, 25.08, 25.14, 25.20, 25.25)

Temp_Sep <- c(24.60, 24.63, 25.27, 24.73, 25.15, 25.17, 25.90, 24.50, 25.17, 25.43, 25.17, 25.20, 25.50, 25.70, 24.80, 27.70, 26.04, 26.13, 26.21, 26.30, 26.39)

Temp_Oct <- c(25.50, 24.90, 25.60, 25.80, 25.80, 24.80, 26.17, 24.47, 25.33, 25.67, 25.17, 24.60, 25.80, 25.60, 25.50, 25.36, 25.36, 25.36, 25.36, 25.35, 25.35)

Temp_Nov <- c(25.47, 25.97, 25.93, 26.00, 26.05, 25.77, 25.90, 25.23, 25.67, 25.93, 24.50, 25.47, 26.55, 25.60, 25.70, 25.60, 25.58, 25.57, 25.55, 25.54, 25.52)

Temp_Dic <- c(26.40, 26.37, 26.67, 26.67, 27.00, 26.30, 27.03, 25.77, 26.50, 26.73, 25.07, 26.43, 27.10, 27.10, 26.80, 26.61, 26.62, 26.63, 26.65, 26.66, 26.67)

modelo <- lm(Produccion ~ Superficie_plantada + Semilla_comun + Semilla_mejorada + Semilla_certificada + Semilla_HN + Semilla_HI + Riego + Superficie_cosechada + Sequia + Helada + Plagas + Enfermedades + Inundacion + Otras_causas + Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios + Ventas, data = Arroz_Nacional)

summary(modelo)

```
ANOVA<- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE) # Otra forma de graficar en 3D es:
```

```
require(scatterplot3d)
```

```
require(rgl)
```

```
sp1 <- scatterplot3d(Produccion, Aplicacion_Fertilizantes,
Aplicacion_Fitosanitarios)
```

```
sp1 <- scatterplot3d(Produccion, Aplicacion_Fertilizantes,
Aplicacion_Fitosanitarios, pch=16, col="red",
highligth.3d=TRUE, angle=120)
```

O, sino:

```
plot3d(Produccion, Aplicacion_Fertilizantes, Aplicacion_
Fitosanitarios, col="red", size=5)
```

```
plot(Semilla_comun, type= 'b', lwd=2, axes=FALSE,
main="Producción de arroz (Oryza sativa): CNA (2000)
```

```
y ESPAC (2002-2020)", ylab="Producción anual (Ton)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Semilla_HN, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Riego, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Superficie_cosechada, type= 'o', lwd=2, axes=FALSE,
col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Sequia, type= 'o', lwd=2, axes=FALSE, col="blueviolet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Helada, type= 'b', lwd=2, axes=FALSE,
col="springgreen2", ann=F)
```

```
par(new=TRUE) 103
```

```
plot(Plagas, type= 'b', lwd=2, axes=FALSE, col="magenta",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Enfermedades, type= 'b', lwd=2, axes=FALSE,
main="Producción de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Producción anual (Ton)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Inundacion, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(APlicacion_Fertilizantes, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(APlicacion_Fitosanitarios, type= 'o', lwd=2, axes=FALSE,
col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="blueviolet",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

plot(modelo) # Archivo comando o Script que proporciona diferentes gráficos de análisis

coef(modelo) # Crea un modelo con los coeficientes de las variables independientes

shapiro.test(rstandard(modelo)) # Se realiza un análisis de la adecuación del modelo mediante pruebas de normalidad de residuos estándar en R. Sus hipótesis de normalidad son:

: Los residuos tienen una distribución “normal”

: Los residuos estándar no tienen una distribución “normal”

qqnorm(rstandard(modelo)) # La programación “qqnorm” hace un gráfico de dispersión de datos residuales normales estándar para ver su comportamiento, mientras que comando “qqline” dibuja una línea sobre estos puntos, cubriendolos

`qqline(rstandard(modelo))` # “qqline” es una línea a la que los residuos deben estar cercanos a ella para tener un comportamiento “normal”. Si no se acepta : Datos tienen distribución normal

`ncvTest(model = modelo)`

`jarque.test(rstandard(modelo))` # Archivo o comando Script que permite hacer la prueba de Jarque Bera para sesgo y curtosis (Si tal que no se acepta : Datos muestrales provienen de una población con distribución normal y, por lo tanto, son datos uniformes, no tienen sesgo ni curtosis para ser normales). En caso de Python, Prob(JB), es al revés Si tal que no se rechaza : Datos muestrales provienen de una población con distribución normal y, por lo tanto, son datos uniformes, no tienen sesgo ni curtosis para ser normales.

`ad.test(rstandard(modelo))` # Ad. Test es la prueba Anderson-Darling (la cantidad de datos debe ser > 7 tal que si no se acepta H_0 : Datos muestrales provienen de una población con distribución normal)

`cvm.test(rstandard(modelo))`#cvm. test es prueba de normalidad de Cramer Von Mises (su cantidad de datos debe ser > 7 tal que si no se acepta : Datos muestrales provienen de una población con distribución normal)

`lillie.test(rstandard(modelo))` # Lillie.test es prueba de Kolmogorov-Smirnov (la cantidad de datos debe ser > 4 tal que si no se acepta : Datos muestrales provienen de una población

con distribución normal)

`pearson.test(rstandard(modelo))` # Pearson.test es prueba de chi cuadrado (si no se acepta : Datos muestrales provienen de una población con distribución normal).

`sf.test(rstandard(modelo))` # Sf.test es prueba de Shapiro-Francia (la cantidad de datos debe ser > 5 y tal que si no se acepta : Datos muestrales provienen de una población con distribución normal)

`transformacion.a.normal <- RE.Jhonson(rstandard(modelo))`

`transformacion.a.normal`

`w <- transformacion.a.normal$tranformed`

`jarque.test(w)` # Archivo o comando Script test de Jhonson hace transformación de variable no normal a normal. W contiene valores de datos transformados (si no se acepta : Datos transformados tienen distribución normal, pero si no se rechaza : Datos transformados tienen distribución normal). Por lo tanto, se recomienda aceptar el mayor. Las pruebas de transformación de Jhonson son:

Tabla 7. Pruebas de transformación de Jhonson

Familia de transformación de Jhonson		
Nom - bre	Ecuación	Rango
SB	$\lambda + \eta + \ln((x - \varepsilon)/(\lambda + \varepsilon - x))$	$\eta\lambda > 0, -\infty < \gamma < \infty,$ $-\infty < \varepsilon < \infty, \varepsilon < x < \varepsilon + \lambda$
SL	$\gamma + \eta \ln(x - \varepsilon)$	$\eta > 0, -\infty < \gamma < \infty,$ $-\infty < \varepsilon < \infty, \varepsilon < x$
SU	$\gamma + \eta \text{Sinh}^{-1}((x - \varepsilon)/\lambda) \text{ tal que}$ $\text{Sinh}^{-1}(x) = \ln((x + \sqrt{(1+x^2)})$	$\eta\lambda > 0, -\infty < \gamma < \infty,$ $-\infty < \varepsilon < \infty, -\infty < x < \infty$

Archivo o comando Script que permite hacer la prueba de Jarque Bera para sesgo y curtosis (Si $p < 0.05$ tal que no se acepta H_0 : Datos tienen distribución normal y, por lo tanto, son datos uniformes, no tienen sesgo ni curtosis para ser normales)

`ad.test(w)` # Ad. Test es la prueba Anderson-Darling (la cantidad de datos debe ser > 7 tal que si $p < 0.05$ no se acepta H_0 : Datos tienen distribución normal)

`lillie.test(w)` # Lillie.test es prueba de Kolmogorov-Smirnov (la cantidad de datos debe ser > 4 tal que $p < 0.05$ si no se acepta H_0 : Datos tienen distribución normal)

`pearson.test(w)` # Pearson.test es prueba de chi cuadrado (si $p < 0.05$ no se acepta H_0 : Datos tienen distribución normal)

`sf.test(w)` # Sf.test es prueba de Shapiro-Francia (la cantidad de datos debe ser > 5 y < 500 tal que si $p < 0.05$ no se acepta H_0 : Datos tienen distribución normal)

: Datos tienen distribución normal)

`levene.test(Produccion, Semilla_comun)` # Prueba de Levene es para homogeneidad de varianzas:

H_0 : Todos los términos tienen misma avarianza

H_a : Al menos uno de los términos tiene varianza significativa
Si $p \geq 0.05$ diferente. Si no se rechaza H_0 y no se acepta H_a .

`levene.test(Produccion, Semilla_HN)`

`levene.test(Produccion, Riego)`

`levene.test(Produccion, Sequia)`

`levene.test(Produccion, Helada)`

`levene.test(Produccion, Plagas)`

`levene.test(Produccion, Enfermedades)`

`levene.test(Produccion, Inundacion)`

`levene.test(Produccion, Aplicacion_Fertilizantes)`

`levene.test(Produccion, Aplicacion_Fitosanitarios)`

levene.test(Produccion, Ventas)

fligner.test(Produccion, Semilla_comun) # Prueba de Fligner es para homogeneidad de varianzas:

H_0 : Todos los términos tienen misma avarianza

H_a : Al menos uno de los términos tiene varianza significativa $\rho \geq 0.05$ diferente. Si no se rechaza H_0 y no se acepta H_a . Este supuesto generalmente no cumple en datos de serie de tiempo por la tendencia que llevan por comportamiento económico. La violación a este supuesto se conoce como autocorrelación tal que si no se cumple tampoco son válidas las pruebas estadísticas del modelo de regresión, pues coeficientes de regresión no tendrán varianza mínima (errores estándar). Hay dos formas de validarla: A. Gráfico de residuales a través de tiempo y B. Prueba Durwin Watson.

fligner.test(Produccion, Semilla_HN)

fligner.test(Produccion, Riego)

fligner.test(Produccion, Sequia)

fligner.test(Produccion, Helada)

fligner.test(Produccion, Plagas)

fligner.test(Produccion, Enfermedades)

fligner.test(Produccion, Inundacion)

fligner.test(Produccion, Aplicacion_Fertilizantes)

fligner.test(Produccion, Aplicacion_Fitosanitarios)

fligner.test(Produccion, Ventas)

dwtest(modelo, alternative = "two.sided") # Prueba Durwin Watson. Va de 0 a 4. Valores pequeños conducen a pensar que existe autocorrelación +, valores grandes autocorrelación -. Prueba de autocorrelación positiva:

H_0 : Términos error “no están autocorrelacionados” o existe independencia lineal de errores

H_a : Términos error “sí están autocorrelacionados” de manera positiva o existe autocorrelación. Prueba de autocorrelación negativa:

H_0 : Términos error “no están autocorrelacionados” o existe independencia lineal de errores

H_a : Términos error “sí están autocorrelacionados” de manera negativa o existe autocorrelación.

dwtest(modelo, alternative = "greater")

dwtest(modelo, alternative = "less")

```
modelo2 <- cochrane.orcutt(modelo, convergence = 4) # Prueba de corrección de autocorrelación de 1er orden Cochrane-Orcutt
```

```
summary(modelo2)
```

```
modelo <- lm(Sequia ~ Precipit_Ene + Precipit_Feb + Precipit_Mar + Precipit_May + Precipit_Jun + Precipit_Oct + Precipit_Dic, data = Arroz_Nacional) # Archivo comando o Script que genera cuadro de Análisis de Varianza para evaluación del modelo lineal general, en inglés general linear model
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo) # Archivo comando o Script que genera cuadro de Análisis de Varianza para evaluación del modelo lineal general, en inglés general linear model
```

```
summary(ANOVA)
```

```
plot(Sequia, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'b', lwd=2, axes=FALSE, main="Superficie perdida de arroz (Oryza sativa): CNA (2000) y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
```

```
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'b', lwd=2, axes=FALSE, col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_May, type= 'o', lwd=2, axes=FALSE, col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'o', lwd=2, axes=FALSE, col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Oct, type= 'o', lwd=2, axes=FALSE, col="blueviolet", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo) # Archivo comando o Script que proporciona diferentes gráficos de análisis
```

```
coef(modelo) # Crea un modelo con los coeficientes de las variables independientes
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lil lie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Helada ~ Precipit_Ene + Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct + Precipit_Nov + Precipit_Dic, data = Arroz_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Helada, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Oct, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Helada ~ Temp_Ene + Temp_Feb + Temp_Mar  
+ Temp_Abr + Temp_May + Temp_Jun + Temp_Jul + Temp_  
Ago + Temp_Sep + Temp_Oct + Temp_Nov + Temp_Dic, data  
= Arroz_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Helada, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Temp_Sep, type= 'b', lwd=2, axes=FALSE,  
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
```

```
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",  
xlab="Año productivo", col="red")
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Plagas ~ Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios + Precipit_Ene + Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_Ene + Temp_Feb + Temp_Mar + Temp_Abr + Temp_May, data = Arroz_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Plagas, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Aplicacion_Fertilizantes, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Aplicacion_Fitosanitarios, type= 'b', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ene, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'o', lwd=2, axes=FALSE,
```

```
col="blueviolet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type= 'b', lwd=2, axes=FALSE,
col="springgreen2", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_May, type= 'b', lwd=2, axes=FALSE,
col="magenta", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Plagas, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Jul, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```

par(new=TRUE)

plot(Precipit_Ago, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)

par(new=TRUE)

plot(Precipit_Sep, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)

par(new=TRUE)

plot(Precipit_Oct, type= 'o', lwd=2, axes=FALSE,
col="blueviolet", ann=F)

par(new=TRUE)

plot(Precipit_Nov, type= 'b', lwd=2, axes=FALSE,
col="springgreen2", ann=F)

par(new=TRUE)

plot(Precipit_Dic, type= 'b', lwd=2, axes=FALSE,
col="magenta", ann=F)

grid(col="black", lwd=0.05)

plot(Plagas, type= 'o', col="black", xaxt="n", lwd=2, ann=F)

```

```

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Temp_Ene, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")

par(new=TRUE)

plot(Temp_Feb, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Temp_Mar, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)

par(new=TRUE)

plot(Temp_Abr, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)

par(new=TRUE)

plot(Temp_May, type= 'o', lwd=2, axes=FALSE,
col="blueviolet", ann=F)

```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Enfermedades ~ Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios + Precipit_Ene + Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_Ene + Temp_Feb + Temp_Mar + Temp_Abr + Temp_May, data = Arroz_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Enfermedades, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(APlicacion_Fertilizantes, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(APlicacion_Fitosanitarios, type= 'b', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ene, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'o', lwd=2, axes=FALSE,
col="blueviolet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type= 'b', lwd=2, axes=FALSE,
col="springgreen2", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_May, type= 'b', lwd=2, axes=FALSE,
col="magenta", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Enfermedades, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Jul, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ago,   type=  'o',   lwd=2,   axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Sep,type='o',lwd=2,axes=FALSE,col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Oct,   type=  'o',   lwd=2,   axes=FALSE,
col="blueviolet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Nov,   type=  'b',   lwd=2,   axes=FALSE,
col="springgreen2", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Dic,   type=  'b',   lwd=2,   axes=FALSE,
col="magenta", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Enfermedades, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Temp_Ene,   type=  'b',   lwd=2,   axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Temp_Feb, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Mar, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Abr, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```

plot(Temp_May, type= 'o', lwd=2, axes=FALSE,
col="blueviolet", ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

```

```

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Inundacion ~ Precipit_Ene + Precipit_Feb +
Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun +
Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct +
Precipit_Nov + Precipit_Dic + Temp_Ene + Temp_Feb +
Temp_Mar + Temp_Abr + Temp_May + Temp_Jun + Temp_Jul +
Temp_Ago + Temp_Sep + Temp_Oct + Temp_Nov + Temp_Dic, data = Arroz_Nacional)

summary(modelo)

```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Inundacion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Ene, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ago, type= 'o', lwd=2, axes=FALSE,
```

```
col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Nov, type= 'o', lwd=2, axes=FALSE,
col="blueviolet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Dic, type= 'b', lwd=2, axes=FALSE,
col="springgreen2", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Inundacion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Temp_Abr, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Temp_Mar, type= 'b', lwd=2, axes=FALSE, col="blue",
```

```

ann=F)

par(new=TRUE)

plot(Temp_Ene, type='o', lwd=2, axes=FALSE, col="yellow",
ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

```

```

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ Credito_Agro_Ene + Credito_
Agro_Feb + Credito_Agro_Mar + Credito_Agro_Abr, data =
Arroz_Nacional)

summary(modelo)

```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Mar, type= 'b', lwd=2, axes=FALSE,
main="Superficie perdida de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

“Provincias productoras de interés (base ESPAC 2002)”

```
getwd()
```

```
library(readxl)
```

```
Arroz_Guayas <- read_excel("G:/Libros para Ingeniería/  
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram  
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos  
ESPAC 2000 a 2019/Arroz.Guayas.xlsx")
```

```
View(Arroz_Guayas)
```

```
str(Arroz_Guayas)
```

```
names(Arroz_Guayas)
```

```
cor(Arroz_Guayas)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",  
"2005", "2006", "2007", "2008", "2009", "2010", "2011",  
"2012", "2013", "2014", "2015", "2016", "2017", "2018",  
"2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(552218, 699815, 847411, 821486, 1094627,  
889417, 942893, 1085050, 889033, 1044704, 1009263, 889011,  
1029783, 1060669, 902424, 1187135, 1035344, 761954,  
981513, 1065864, 1079168)
```

```
Superficie_plantada <- c(185429, 196996, 208562, 209396,  
249685, 229560, 217442, 242061, 222330, 253747, 248783,  
240774, 257294, 273879, 233126, 274992, 247640, 253690,  
210262, 262264, 265039)
```

```
Ventas <- c(816988, 825166, 747725, 729851, 978223, 811611,  
888077, 1002731, 796427, 971962, 927327, 809744, 952116,  
1016229, 852177, 1120058, 979301, 731295, 964191, 972368,  
980546)
```

```
Precipit_Jul <- c(47.28, 0.50, 0.70, 1.00, 0.25, 0.00, 0.00,  
0.00, 0.00, 2.90, 23.75, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,  
0.00, 0.00)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Ventas, data  
= Arroz_Guayas)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
```

```
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE,
main="Producción de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jul,type='o',lwd=2,axes=FALSE,col="yellow",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
getwd()
```

```
library(readxl)
```

```
Arroz_Loja<-read_excel("G:/Libros para Ingeniería/Regresión  
lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler  
y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/  
Arroz.Loja.xlsx")
```

```
View(Arroz_Loja)
```

```
str(Arroz_Loja)
```

```
names(Arroz_Loja)
```

```
cor(Arroz_Loja)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",  
"2005", "2006", "2007", "2008", "2009", "2010", "2011",  
"2012", "2013", "2014", "2015", "2016", "2017", "2018",  
"2019", "2020")
```

```
V<-c(1:21)
```

```
Produccion <- c(6029, 7614, 9200, 9259, 7800, 8151, 8953,  
20024, 19564, 7632, 13441, 50746, 24892, 20655, 15615,  
10575, 6030, 1485, 2230, 4855, 3129)
```

```
Superficie_plantada <- c(1864, 1636, 1408, 1603, 1537, 1597,  
1480, 3070, 2978, 1473, 3563, 6700, 6414, 3332, 2436, 1541,  
1045, 549, 692, 1066, 797)
```

```
Ventas <- c(11259, 11448, 9159, 8707, 7685, 8055, 8288,  
11816, 17851, 6830, 9091, 50431, 22778, 19653, 13952, 8252,  
4868, 1485, 8616, 7522, 6428)
```

```
Precipit_Jun <- c(7.10, 0.00, 0.00, 0.00, 0.00, 4.60, 0.00, 0.00,  
2.90, 0.00, 4.00, 15.30, 7.65, 0.00, 0.00, 0.00, 0.00, 0.00,  
0.00, 0.00)
```

```
Precipit_Dic <- c(85.20, 4.80, 0.00, 6.50, 13.50, 10.40, 6.60,  
0.00, 0.00, 9.10, 5.30, 1.50, 0.00, 0.00, 0.00, 0.00, 0.00,  
0.00, 0.00, 0.00)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Superficie_  
cosechada + Ventas, data = Arroz_Loja)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE,
main="Producción de arroz provincia Loja (Oryza sativa): CNA (2000) y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)", xlab="Año productivo", col="red")

par(new=TRUE)

plot(Ventas, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Precipit_Jun, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)

par(new=TRUE)

plot(Precipit_Dic, type='o', lwd=2, axes=FALSE, col="violet",
ann=F)

grid(col="black", lwd=0.05)

```

```

plot(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$transformed

```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
getwd()
```

```
library(readxl)
```

```
Arroz_LosRios <- read_excel("G:/Libros para Ingeniería/  
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram  
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos  
ESPAC 2000 a 2019/Arroz.LosRios.xlsx")
```

```
View(Arroz_LosRios)
```

```
str(Arroz_LosRios)
```

```
names(Arroz_LosRios)
```

```
cor(Arroz_LosRios)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",  
"2005", "2006", "2007", "2008", "2009", "2010", "2011",  
"2012", "2013", "2014", "2015", "2016", "2017", "2018",  
"2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(370294, 434805, 499315, 486498, 602564,  
515347, 480594, 566821, 463503, 449749, 615660, 464427,  
444330, 359569, 410850, 383106, 421483, 242879, 317198,  
249890, 218546)
```

```
Superficie_plantada <- c(131886, 133872, 135858, 129519,  
150426, 150731, 132744, 144934, 137525, 140707, 140941,  
113437, 126296, 114545, 118087, 100961, 114201, 96920,  
77720, 83106, 77435)
```

```
Ventas <- c(527012, 515185, 431471, 435135, 549644, 469634,  
442819, 513440, 388385, 406343, 565334, 375081, 388864,  
330812, 376414, 345966, 386324, 228746, 314117, 248479,  
224582)
```

```
Precipit_Jun <- c(9.27, 0.10, 5.47, 12.23, 10.13, 0.00, 13.07,  
15.53, 2.67, 14.57, 8.27, 36.17, 36.85, 3.90, 7.50, 159.60, 55.59,  
59.67, 63.74, 67.82, 71.89)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Ventas, data  
= Arroz_LosRios)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
modelo <- lm(Produccion ~ Precipit_Ene + Precipit_Feb +
Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun +
Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct +
Precipit_Nov + Precipit_Dic, data = Arroz_LosRios)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE,
main="Producción de arroz (Oryza sativa): CNA (2000)
y ESPAC (2002-2020)", ylab="Superficie afectada (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```

lillie.test(rstandard(modelo))
pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

```

1.1.1 Ejemplo 2. “Banano.Nacional”

```

getwd()
library(readxl)
Banano_Nacional <- read_excel("G:/Libros para Ingeniería/

```

Regresión lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/Banano.Nacional.xlsx”)

```

View(Banano_Nacional)

str(Banano_Nacional)

names(Banano_Nacional)

cor(Banano_Nacional)

modelo <- lm(Produccion ~ Superficie_plantada + Semilla_comun + Semilla_mejorada + Semilla_HN + Semilla_HI + Riego + Superficie_cosechada + Sequia + Helada + Plagas + Enfermedades + Inundacion + Otras_causas + Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios + Ventas + Precios_Prod_Pond_C_Ene + Precios_Prod_Pond_C_Feb + Precios_Prod_Pond_C_Mar + Precios_Prod_Pond_C_Abr + Precios_Prod_Pond_C_May + Precios_Prod_Pond_C_Jun + Precios_Prod_Pond_C_Jul + Precios_Prod_Pond_C_Ago + Precios_Prod_Pond_C_Sep + Precios_Prod_Pond_C_Oct + Precios_Prod_Pond_C_Nov + Precios_Prod_Pond_C_Dic + Precios_Prod_Pond_CE_Ene + Precios_Prod_Pond_CE_Feb + Precios_Prod_Pond_CE_Mar + Precios_Prod_Pond_CE_Abr + Precios_Prod_Pond_CE_May + Precios_Prod_Pond_CE_Jun + Precios_Prod_Pond_CE_Jul + Precios_Prod_Pond_CE_Ago + Precios_Prod_Pond_CE_Sep + Precios_Prod_Pond_CE_Oct + Precios_Prod_Pond_CE_Nov + Precios_Prod_Pond_CE_Dic

```

+ Precios_Prod_Pond_CS_Ene + Precios_Prod_Pond_CS_Feb
 + Precios_Prod_Pond_CS_Mar + Precios_Prod_Pond_CS_Abr
 + Precios_Prod_Pond_CS_May + Precios_Prod_Pond_CS_Jun
 + Precios_Prod_Pond_CS_Jul + Precios_Prod_Pond_CS_Ago
 + Precios_Prod_Pond_CS_Sep + Precios_Prod_Pond_CS_Oct
 + Precios_Prod_Pond_CS_Nov + Precios_Prod_Pond_CS_Dic
 + Precios_Mer_May_Ene + Precios_Mer_May_Feb + Precios_Mer_May_Mar + Precios_Mer_May_Abr + Precios_Mer_May_May + Precios_Mer_May_Jun + Precios_Mer_May_Jul + Precios_Mer_May_Ago + Precios_Mer_May_Sep + Precios_Mer_May_Oct + Precios_Mer_May_Nov + Precios_Mer_May_Dic + Fosfato_diam_Fert_Ene + Fosfato_diam_Fert_Feb + Fosfato_diam_Fert_Mar + Fosfato_diam_Fert_Abr + Fosfato_diam_Fert_May + Fosfato_diam_Fert_Jun + Fosfato_diam_Fert_Jul + Fosfato_diam_Fert_Ago + Fosfato_diam_Fert_Sep + Fosfato_diam_Fert_Oct + Fosfato_diam_Fert_Nov + Fosfato_diam_Fert_Dic + Muriato_K_Fert_Ene + Muriato_K_Fert_Feb + Muriato_K_Fert_Mar + Muriato_K_Fert_Abr + Muriato_K_Fert_May + Muriato_K_Fert_Jun + Muriato_K_Fert_Jul + Muriato_K_Fert_Ago + Muriato_K_Fert_Sep + Muriato_K_Fert_Oct + Muriato_K_Fert_Nov + Muriato_K_Fert_Dic + Urea_Fert_Ene + Urea_Fert_Feb + Urea_Fert_Mar + Urea_Fert_Abr + Urea_Fert_May + Urea_Fert_Jun + Urea_Fert_Jul + Urea_Fert_Ago + Urea_Fert_Sep + Urea_Fert_Oct + Urea_Fert_Nov + Urea_Fert_Dic + Propiconazol_Fungi_Ene + Propiconazol_Fungi_Feb + Propiconazol_Fungi_Mar + Propiconazol_Fungi_Abr + Propiconazol_Fungi_May + Propiconazol_Fungi_Jun + Propiconazol_Fungi_Jul + Propiconazol_Fungi_Ago +

Propiconazol_Fungi_Sep + Propiconazol_Fungi_Oct + Propiconazol_Fungi_Nov + Propiconazol_Fungi_Dic + Cimo_Manco_Fungi_Ene + Cimo_Manco_Fungi_Feb + Cimo_Manco_Fungi_Mar + Cimo_Manco_Fungi_Abr + Cimo_Manco_Fungi_May + Cimo_Manco_Fungi_Jun + Cimo_Manco_Fungi_Jul + Cimo_Manco_Fungi_Ago + Cimo_Manco_Fungi_Sep + Cimo_Manco_Fungi_Oct + Cimo_Manco_Fungi_Nov + Cimo_Manco_Fungi_Dic + Carbendazim_Fungi_Ene + Carbendazim_Fungi_Feb + Carbendazim_Fungi_Mar + Carbendazim_Fungi_Abr + Carbendazim_Fungi_May + Carbendazim_Fungi_Jun + Carbendazim_Fungi_Jul + Carbendazim_Fungi_Ago + Carbendazim_Fungi_Sep + Carbendazim_Fungi_Oct + Carbendazim_Fungi_Nov + Carbendazim_Fungi_Dic + Clorotalonil_Fungi_Ene + Clorotalonil_Fungi_Feb + Clorotalonil_Fungi_Mar + Clorotalonil_Fungi_Abr + Clorotalonil_Fungi_May + Clorotalonil_Fungi_Jun + Clorotalonil_Fungi_Jul + Clorotalonil_Fungi_Ago + Clorotalonil_Fungi_Sep + Clorotalonil_Fungi_Oct + Clorotalonil_Fungi_Nov + Clorotalonil_Fungi_Dic + Glifosato_Herbicide_Ene + Glifosato_Herbicide_Feb + Glifosato_Herbicide_Mar + Glifosato_Herbicide_Abr + Glifosato_Herbicide_May + Glifosato_Herbicide_Jun + Glifosato_Herbicide_Jul + Glifosato_Herbicide_Ago + Glifosato_Herbicide_Sep + Glifosato_Herbicide_Oct + Glifosato_Herbicide_Nov + Glifosato_Herbicide_Dic + Paraquat_Herbicide_Ene + Paraquat_Herbicide_Feb + Paraquat_Herbicide_Mar + Paraquat_Herbicide_Abr + Paraquat_Herbicide_May + Paraquat_Herbicide_Jun + Paraquat_Herbicide_Jul + Paraquat_Herbicide_Ago + Paraquat_Herbicide_Sep + Paraquat_Herbicide_Oct + Paraquat_Herbicide_Nov

Nov + Paraquat_Herbi_Dic + Pendimetalina_Herbi_Ene +
 Pendimetalina_Herbi_Feb + Pendimetalina_Herbi_Mar +
 Pendimetalina_Herbi_Abr + Pendimetalina_Herbi_May +
 Pendimetalina_Herbi_Jun + Pendimetalina_Herbi_Jul +
 Pendimetalina_Herbi_Ago + Pendimetalina_Herbi_Sep +
 Pendimetalina_Herbi_Oct + Pendimetalina_Herbi_Nov +
 Pendimetalina_Herbi_Dic + Propanil_Herbi_Ene + Propanil_
 Herbi_Feb + Propanil_Herbi_Mar + Propanil_Herbi_Abr +
 Propanil_Herbi_May + Propanil_Herbi_Jun + Propanil_Herbi_
 Jul + Propanil_Herbi_Ago + Propanil_Herbi_Sep + Propanil_
 Herbi_Oct + Propanil_Herbi_Nov + Propanil_Herbi_Dic +
 Dos_Cuatro_Damina_Herbi_Ene + Dos_Cuatro_Damina_
 Herbi_Feb + Dos_Cuatro_Damina_Herbi_Mar + Dos_Cuatro_
 Damina_Herbi_Abr + Dos_Cuatro_Damina_Herbi_May +
 Dos_Cuatro_Damina_Herbi_Jun + Dos_Cuatro_Damina_
 Herbi_Jul + Dos_Cuatro_Damina_Herbi_Ago + Dos_Cuatro_
 Damina_Herbi_Sep + Dos_Cuatro_Damina_Herbi_Oct + Dos_
 Cuatro_Damina_Herbi_Nov + Dos_Cuatro_Damina_Herbi_
 Dic + Atrazina_Herbi_Ene + Atrazina_Herbi_Feb +
 Atrazina_Herbi_Mar + Atrazina_Herbi_Abr + Atrazina_Herbi_
 May + Atrazina_Herbi_Jun + Atrazina_Herbi_Jul + Atrazina_
 Herbi_Ago + Atrazina_Herbi_Sep + Atrazina_Herbi_Oct +
 Atrazina_Herbi_Nov + Atrazina_Herbi_Dic + Clorpiriphos_
 Insect_Ene + Clorpiriphos_Insect_Feb + Clorpiriphos_Insect_
 Mar + Clorpiriphos_Insect_Abr + Clorpiriphos_Insect_May +
 Clorpiriphos_Insect_Jun + Clorpiriphos_Insect_Jul +
 Clorpiriphos_Insect_Ago + Clorpiriphos_Insect_Sep +
 Clorpiriphos_Insect_Oct + Clorpiriphos_Insect_Nov +
 Clorpiriphos_Insect_Dic + Cipermetrina_Insect_Ene +

Cipermetrina_Insect_Feb + Cipermetrina_Insect_Mar +
 Cipermetrina_Insect_Abr + Cipermetrina_Insect_May +
 Cipermetrina_Insect_Jun + Cipermetrina_Insect_Jul +
 Cipermetrina_Insect_Ago + Cipermetrina_Insect_Sep +
 Cipermetrina_Insect_Oct + Cipermetrina_Insect_Nov +
 Cipermetrina_Insect_Dic + I_Gini_Rural_ISem + I_Gini_
 Rural_IISem + I_Gini_Nacional_ISem + I_Gini_Nacional_
 IISem + Credito_Agro_Ene + Credito_Agro_Feb + Credito_
 Agro_Mar + Credito_Agro_Abr + Credito_Agro_May +
 Credito_Agro_Jun + Credito_Agro_Jul + Credito_Agro_Ago +
 Credito_Agro_Sep + Credito_Agro_Oct + Credito_Agro_Nov
 + Credito_Agro_Dic + Empl_Tot_ITrim + Empl_Tot_IITrim +
 Empl_Tot_IIITrim + Empl_Tot_IVTrim + Empl_Agrop_ITrim
 + Empl_Agrop_IITrim + Empl_Agrop_IIITrim + Empl_
 Agrop_IVTrim + Tasa_empl_adec_Rural_ITrim + Tasa_empl_
 adeRural_IITrim + Tasa_empl_adec_Rural_IIITrim + Tasa_
 empl_adec_Rural_IVTrim + Tasa_sub_empl_adec_Rural_
 I T r i m
 + Tasa_sub_empl_adec_Rural_IITrim + Tasa_sub_empl_adec_
 Rural_IIITrim + Tasa_sub_empl_adec_Rural_IVTrim + Tasa_
 otro_empl_no_pleno_Rural_ITrim + Tasa_otro_empl_no_
 pleno_Rural_IITrim + Tasa_otro_empl_no_pleno_Rural_
 I T r i m
 + Tasa_otro_empl_no_pleno_Rural_IVTrim + Tasa_empl_no_
 remun_Rural_ITrim + Tasa_empl_no_remun_Rural_IITrim +
 Tasa_empl_no_remun_Rural_IIITrim + Tasa_empl_no_
 remun_Rural_IVTrim + Tasa_desem_adecuado_Rural_ITrim +
 Tasa_desem_adecuado_Rural_IITrim + Tasa_desem_
 adecuado_Rural_IIITrim + Tasa_desem_adecuado_Rural_

```

IVTrim + Pob_ingresos_Rural_ISem + Pob_ingresos_Rural_
I           I           S           e           m
+ Pob_extrem_ingeros_Rural_ISem + Pob_extrem_ingeros_
Rural_IITSem + IPA + TPA + TPIAR + TVAA + IPP_N_Ene +
IPP_N_Feb + IPP_N_Mar + IPP_N_Abr + IPP_N_May +
IPP_N_Jun + IPP_N_Jul + IPP_N_Ago + IPP_N_Sep +
IPP_N_Oct + IPP_N_Nov + IPP_N_Dic + IPP_X_Ene +
IPP_X_Feb + IPP_X_Mar + IPP_X_Abr + IPP_X_May +
IPP_X_Jun + IPP_X_Jul + IPP_X_Ago + IPP_X_Sep +
IPP_X_Oct + IPP_X_Nov + IPP_X_Dic + IPM_Ene + IPM_
Feb + IPM_Mar + IPM_Abr + IPM_May + IPM_Jun + IPM_
Jul + IPM_Ago + IPM_Sep + IPM_Oct + IPM_Nov + IPM_Dic
+ IPX_Ene + IPX_Feb + IPX_Mar + IPX_Abr + IPX_May +
IPX_Jun + IPX_Jul + IPX_Ago + IPX_Sep + IPX_Oct + IPX_
Nov + IPX_Dic + IPI_Ene + IPI_Feb + IPI_Mar + IPI_Abr +
IPI_May + IPI_Jun + IPI_Jul + IPI_Ago + IPI_Sep + IPI_Oct +
IPI_Nov + IPI_Dic + IPF_Ene + IPF_Feb + IPF_Mar + IPF_
Abr + IPF_May + IPF_Jun + IPF_Jul + IPF_Ago + IPF_Sep +
IPF_Oct + IPF_Nov + IPF_Dic + IBC_Ene + IBC_Feb + IBC_
Mar + IBC_Abr + IBC_May + IBC_Jun + IBC_Jul + IBC_Ago
+ IBC_Sep + IBC_Oct + IBC_Nov + IBC_Dic + IPCA_Ene +
IPCA_Feb + IPCA_Mar + IPCA_Abr + IPCA_May + IPCA_
Jun + IPCA_Jul + IPCA_Ago + IPCA_Sep + IPCA_Oct +
IPCA_Nov + IPCA_Dic + Inf_Men_Ene + Inf_Men_Feb +
Inf_Men_Mar + Inf_Men_Abr + Inf_Men_May + Inf_Men_
Jun + Inf_Men_Jul + Inf_Men_Ago + Inf_Men_Sep + Inf_
Men_Oct + Inf_Men_Nov + Inf_Men_Dic + Precipit_Ene +
Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May +
Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep +

```

```

Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_Ene +
Temp_Feb + Temp_Mar + Temp_Abr + Temp_May + Temp_
Jun + Temp_Jul + Temp_Ago + Temp_Sep + Temp_Oct +
Temp_Nov + Temp_Dic, data = Banano_Nacional)

```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",
"2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "2018",
"2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(5512204, 5561821, 5611438, 6453806,
6132276, 6118425, 6127060, 6002302, 6701146, 7637324,
7931060, 7427776, 7012244, 5995527, 6756254, 7194431,
6529676, 6282105, 6468924, 7104847, 7165564)
```

```
Superficie_plantada <- c(266125, 251992, 237859, 243949,
240009, 232780, 221107, 211843, 233427, 229602, 235773,
200110, 221775, 217874, 192676, 195533, 186222, 166972,
170809, 174806, 170411)
```

```
Semilla_HN <- c(1616, 3267, 4918, 6570, 8221, 9872, 1795,
8941, 16787, 12976, 24636, 45958, 15647, 11917, 28409,
37381, 25642, 17165, 31337, 32988, 34639)
```

```
Riego <- c(148476, 152720, 156964, 166320, 155590, 159452,
158708, 154047, 163276, 171977, 174514, 116366, 176596,
159656, 170557, 165662, 164960, 147573, 148477, 154516,
160556)
```

```
Sequia <- c(665, 515, 364, 441, 163, 658, 172, 121, 195, 2018,
1969, 836, 419, 922, 522, 267, 456, 19, 666, 653, 641)
```

```
Ventas <- c(4530827, 4559960, 4589092, 5146697, 5146697,
5386887, 5342768, 5285826, 6125021, 6689933, 6895387,
6850162, 6600428, 5705285, 6545064, 7018621, 6341613,
6056309, 4530827, 5757147, 6983467)
```

```
Precios_Prod_Pond_CE_Ene <- c(1.01, 1.01, 1.44, 1.88, 2.31,
2.74, 9.25, 6.21, 3.17, 3.60, 4.03, 4.46, 4.89, 9.25, 7.23, 5.20,
7.39, 3.35, 7.90, 7.10, 9.25)
```

```
Precios_Prod_Pond_CE_May <- c(12.83, 12.40, 11.97, 11.55,
11.12, 10.69, 10.26, 9.83, 9.40, 8.97, 8.54, 8.12, 7.69, 9.63,
5.08, 4.23, 6.55, 7.46, 2.78, 6.08, 4.26)
```

```
Precios_Prod_Pond_CE_Ago <- c(13.42, 12.87, 12.32, 11.76,
11.21, 10.66, 10.11, 9.56, 9.01, 8.46, 7.91, 7.36, 6.81, 6.26,
5.89, 4.48, 6.20, 2.20, 4.27, 2.96, 2.40)
```

```
Precios_Prod_Pond_CS_Nov <- c(2.68, 2.88, 3.08, 3.28, 3.49,
3.69, 3.89, 4.09, 4.29, 4.50, 4.70, 4.90, 5.10, 6.66, 5.48, 3.52,
4.58, 8.64, 5.97, 6.52, 6.72)
```

```
Precios_Prod_Pond_CE_Dic <- c(7.65, 7.51, 7.36, 7.22, 7.07,
6.93, 6.78, 6.64, 6.49, 6.35, 6.20, 6.06, 5.92, 9.25, 2.89, 4.14,
3.00, 7.44, 5.74, 4.90, 4.76)
```

```
Precios_Prod_Pond_CS_Dic <- c(0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.15, 1.05, 1.95, 2.86, 3.80,
3.19, 8.39, 5.09, 7.38, 8.28)
```

```
Precios_Mer_May_Ene <- c(0.00, 0.00, 0.33, 0.74, 1.16, 1.58,
2.00, 2.41, 2.83, 3.25, 3.66, 4.08, 3.92, 5.70, 5.37, 5.63, 5.54,
7.12, 7.40, 6.97, 7.83)
```

```
Precios_Mer_May_Abr <- c(0.49, 0.86, 1.24, 1.61, 1.98, 2.36,
2.73, 3.11, 3.48, 3.85, 4.23, 4.60, 4.66, 5.75, 5.79, 6.36, 5.62,
7.14, 7.56, 7.37, 7.96)
```

```
Credito_Agro_Mar <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, -4633604.52, -2218798.86,
196006.81, 3385244.18, 3476754.73, 8214855.51, 9855229.47,
12270035.14)
```

```
Credito_Agro_Abr <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 2438013.40, 2795478.68,
3152943.96, 3883636.43, 3121420.15, 4598566.99,
4582805.08, 4940270.36)
```

```
Credito_Agro_Jun <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 5198497.00, 5559624.75,
5920752.49, 5003799.89, 9199168.67, 5726055.38,
7365263.47, 7726391.22)
```

```
Credito_Agro_Ago <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 10750.00,
3308657.40, 5142438.20, 5161225.47, 4213314.69,
6390008.43)
```

```
Pob_ingr_Rural_ISem <- c(0.69, 0.67, 0.66, 0.64, 0.62, 0.60,
0.58, 0.57, 0.58, 0.55, 0.53, 0.50, 0.45, 0.41, 0.42, 0.38, 0.41,
0.41, 0.43, 0.35, 0.34)
```

```
Pob_ingr_Rural_IISem <- c(0.77, 0.74, 0.72, 0.70, 0.67, 0.65,
0.62, 0.61, 0.60, 0.58, 0.53, 0.51, 0.49, 0.42, 0.35, 0.39, 0.38,
0.39, 0.40, 0.32, 0.29)
```

```
Pob_extrem_ingresos_Rural_ISem <- c(0.41, 0.40, 0.38, 0.37,
0.35, 0.34, 0.32, 0.31, 0.31, 0.30, 0.28, 0.25, 0.20, 0.17, 0.16,
0.15, 0.19, 0.18, 0.18, 0.12, 0.11)
```

```
Precipit_Feb <- c(185.80, 87.10, 153.60, 88.10, 36.50, 41.45,
154.80, 120.90, 474.50, 222.05, 511.83, 419.00, 571.58, 446.00,
509.12, 480.87, 572.32, 544.07, 515.82, 607.26, 618.91)
```

```
Precipit_Mar <- c(196.75, 115.60, 126.90, 56.00, 92.30, 149.20,
78.60, 531.20, 579.80, 149.75, 367.10, 316.53, 489.75, 373.85,
445.56, 467.54, 441.74, 463.72, 485.69, 459.89, 465.94)
```

```
Precipit_Abr <- c(193.40, 98.20, 111.60, 47.20, 78.00, 114.35,
18.40, 67.58, 264.18, 143.93, 306.35, 446.20, 297.93, 350.75,
461.27, 511.26, 561.25, 611.24, 661.23, 711.22, 761.21)
```

```
Precipit_May <- c(202.05, 78.60, 1.00, 20.60, 17.00, 2.80,
26.55, 5.20, 12.80, 95.63, 89.95, 16.80, 268.70, 186.75, 236.10,
273.01, 309.91, 346.82, 383.73, 420.64, 457.54)
```

```
Precipit_Sep <- c(9.77, 18.45, 21.18, 14.96, 13.39, 9.72, 12.00,
8.83, 14.35, 4.80, 11.03, 32.60, 5.80, 17.66, 14.00, 16.56, 17.07,
17.57, 18.07, 18.57, 19.08)
```

```
Precipit_Oct <- c(23.02, 23.00, 24.83, 25.46, 24.44, 19.50,
15.68, 9.73, 11.05, 10.40, 10.15, 7.08, 10.18, 11.86, 5.38, 3.94,
2.50, 1.06, -0.38, -1.81, -3.25)
```

```
Temp_Ene <- c(29.31, 28.98, 29.06, 28.78, 28.66, 28.43, 27.71,
27.33, 26.11, 26.43, 26.65, 25.83, 25.43, 25.13, 24.85, 24.50,
24.16, 23.82, 23.48, 23.13, 22.79)
```

```
Temp_Feb <- c(26.05, 26.60, 26.28, 26.50, 26.55, 26.53, 26.10,
26.57, 25.98, 26.00, 26.85, 26.43, 26.18, 26.50, 26.36, 26.24,
26.48, 26.36, 26.23, 26.48, 26.48)
```

```
Temp_Mar <- c(26.55, 26.85, 26.85, 26.95, 26.95, 26.95, 26.70,
26.94, 26.65, 26.75, 26.95, 27.08, 27.05, 26.70, 26.93, 26.94,
26.94, 26.95, 26.96, 26.97, 26.98)
```

```
Temp_Abr <- c(26.53, 26.75, 26.63, 26.90, 26.63, 27.00, 26.63,
```

```
26.84, 27.08, 26.98, 27.20, 26.70, 27.15, 26.90, 27.08, 27.11,
27.15, 27.18, 27.21, 27.24, 27.27)
```

```
Temp_May <- c(25.09, 24.99, 26.02, 26.10, 25.83, 25.81,
25.94, 26.26, 26.05, 26.53, 26.78, 26.65, 26.95, 26.30, 26.95,
27.07, 27.18, 27.30, 27.41, 27.53, 27.64)
```

```
Temp_Jun <- c(23.48, 23.40, 24.35, 24.13, 24.20, 24.28, 24.30,
24.83, 25.05, 25.38, 25.28, 25.80, 26.15, 25.38, 26.11, 26.30,
26.48, 26.67, 26.86, 27.04, 27.23)
```

```
Temp_Jul <- c(23.44, 23.74, 24.30, 24.10, 23.96, 24.36, 24.02,
24.67, 24.68, 24.95, 24.80, 25.25, 25.23, 24.65, 25.30, 25.41,
25.53, 25.64, 25.76, 25.87, 25.99)
```

```
Temp_Ago <- c(24.39, 24.02, 24.50, 24.63, 24.36, 24.24, 24.57,
24.40, 24.68, 24.85, 24.48, 24.43, 24.88, 24.48, 24.70, 24.72,
24.75, 24.78, 24.81, 24.83, 24.86)
```

```
Temp_Sep <- c(25.28, 24.94, 25.29, 24.92, 25.25, 24.93, 25.06,
24.89, 25.35, 25.10, 24.73, 25.20, 25.00, 24.92, 24.97,
24.95, 24.94, 24.93, 24.91, 24.90, 24.89)
```

```
Temp_Oct <- c(27.88, 27.11, 27.23, 26.96, 26.78, 25.81, 26.18,
25.31, 25.58, 25.20, 24.80, 24.45, 25.18, 24.73, 24.72, 24.68,
24.63, 24.59, 24.54, 24.50, 24.45)
```

```
Temp_Nov <- c(26.20, 26.08, 26.15, 25.83, 25.60, 25.33, 25.45,
25.28, 25.23, 25.60, 24.18, 25.75, 26.10, 25.88, 26.02, 26.21,
```

```
26.40, 26.59, 26.78, 26.98, 27.17)
```

```
Temp_Dic <- c(26.18, 25.81, 26.13, 26.36, 26.23, 25.41, 26.13,
25.76, 26.01, 26.53, 25.05, 26.48, 26.06, 25.96, 25.95, 25.94,
25.94, 25.93, 25.92, 25.91, 25.91)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Semilla_HN
+ Riego + Sequia + Ventas, data = Banano_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE, main
= "Producción de banano (Musa sp): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Semilla_HN, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)
```

```
plot(Riego, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Sequia, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="chartreuse",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Precios_Prod_Pond_CE_Ago +
Precios_Prod_Pond_CS_Nov, data = Banano_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CE_Ago, type= 'b', lwd=2,
axes=FALSE, main = "Producción de banano (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Producción anual
(Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CS_Nov, type= 'b', lwd=2,
axes=FALSE, col="blue", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Ventas ~ Precios_Prod_Pond_CE_Ene +
  Precios_Prod_Pond_CE_May + Precios_Prod_Pond_CE_Dic +
  Precios_Prod_Pond_CS_Dic + Precios_Mer_May_Ene +
  Precios_Mer_May_Abr, data = Banano_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Ventas, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CE_Ene, type= 'b', lwd=2,
  axes=FALSE, main = "Producción de banano (Musa sp): CNA
  (2000) y ESPAC (2002-2020)", ylab = "Producción anual
  (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CE_May, type= 'b', lwd=2,
  axes=FALSE, col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CE_Dic, type= 'o', lwd=2,
  axes=FALSE, col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precios_Prod_Pond_CS_Dic, type= 'o', lwd=2,
  axes=FALSE, col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precios_Mer_May_Ene, type= 'o', lwd=2, axes=FALSE,
  col="chartreuse", ann=F)
```

```

par(new=TRUE)

plot(Precios_Mer_May_Abr, type= 'o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)
grid(col="black", lwd=0.05)

modelo
plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

```

```

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$transformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ Credito_Agro_Mar + Credito_Agro_Abr + Credito_Agro_Jun + Credito_Agro_Ago + Pob_ingr_Rural_ISem + Pob_ingr_Rural_IISem + Pob_extrem_ingresos_Rural_ISem, data = Banano_Nacional)

summary(modelo)

```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Mar, type= 'b', lwd=2, axes=FALSE, main =
= "Producción de banano (Musa sp): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Abr, type= 'b', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Jun, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Ago, type= 'o', lwd=2, axes=FALSE,
```

```
col="violet", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Pob_ingr_Rural_ISem, type= 'b', lwd=2, axes=FALSE,
main = "Producción de banano (Musa sp): CNA (2000) y
ESPAC (2002-2020)", ylab = "Producción anual (Ton)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Pob_ingr_Rural_IISem, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Pob_extrem_ingresos_Rural_ISem, type= 'o', lwd=2,
axes=FALSE, col="violet", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

```

```

w <- transformacion.a.normal$transformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Sequia ~ Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Sep + Precipit_Oct + Temp_Ene + Temp_Feb + Temp_Mar + Temp_Abr + Temp_May + Temp_Jun + Temp_Jul + Temp_Ago + Temp_Sep + Temp_Oct + Temp_Nov + Temp_Dic, data = Banano_Nacional)

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Sequia, type= 'o', col="black", xaxt="n", lwd=2, ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

```

```
plot(Precipit_Feb, type= 'b', lwd=2, axes=FALSE, main
= "Producción de banano (Musa sp): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_May, type= 'o', lwd=2, axes=FALSE,
col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Sep, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Oct, type= 'o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Sequia, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Temp_Ene, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano (Musa sp): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Temp_Feb, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Mar, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Abr, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```

plot(Temp_May, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)

par(new=TRUE)

plot(Temp_Jun, type= 'o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)

grid(col="black", lwd=0.05)

plot(Sequia, type= 'o', col="black", xaxt="n", lwd=2, ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Temp_Jul, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano (Musa sp): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")

par(new=TRUE)

plot(Temp_Ago, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Temp_Sep, type= 'o', lwd=2, axes=FALSE, col="yellow",

```

```

ann=F)

par(new=TRUE)

plot(Temp_Oct, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)

par(new=TRUE)

plot(Temp_Nov, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)

par(new=TRUE)

plot(Temp_Dic, type= 'o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

“Provincias productoras de interés (base ESPAC 2002)”

```
getwd()
```

```
library(readxl)
```

Banano_Bolivar <- read_excel("G:/Libros para Ingeniería/
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos
ESPAC 2000 a 2019/Banano.Bolivar.xlsx")

```
View(Banano_Bolivar)
```

```
str(Banano_Bolivar)
```

```
names(Banano_Bolivar)
```

```
cor(Banano_Bolivar)
```

También, se pueden ingresar variables de interés así:

Anualidad <- c("2000", "2001", "2002", "2003", "2004",
"2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "2018",
"2019", "2020")

```
V <- c(1:21)
```

```
Produccion <- c(88215, 46708, 5201, 15946, 18285, 23627,  
37516, 27789, 14949, 16272, 11464, 18288, 28929, 17584,  
38671, 40112, 24822, 7402, 5849, 26563, 27264)
```

```
Superficie_plantada <- c(13546, 7161, 775, 6779, 6405, 8335,  
7407, 9370, 9162, 7141, 6620, 3764, 6444, 4072, 3429, 4715,  
2910, 1352, 1530, 1647, 1087)
```

```
Superficie_cosechada <- c(13277, 7011, 744, 6612, 5962, 8196,  
7288, 9269, 9120, 7073, 5796, 3455, 6108, 3608, 3052, 4164,  
2390, 967, 1511, 1254, 713)
```

```
Ventas <- c(9014, 9720, 1742, 12131, 14929, 14867, 24230,  
17064, 9819, 9705, 7279, 13663, 19042, 14095, 34842, 33175,  
19673, 5320, 21726, 22433, 23139)
```

```
Precipit_Ene <- c(57.00, 149.50, 11.50, 114.50, 99.90, 51.00,  
227.85, 193.85, 316.20, 379.95, 238.70, 228.45, 256.25, 160.30,  
219.91, 213.18, 206.45, 199.72, 192.99, 186.26, 179.53)
```

```
Precipit_Feb <- c(133.40, 75.00, 104.50, 164.00, 212.60, 125.60,  
507.10, 441.40, 418.55, 298.45, 355.95, 211.85, 355.50, 355.70,  
258.14, 233.71, 209.28, 184.86, 160.43, 136.00, 111.58)
```

```
Precipit_Mar <- c(89.70, 195.20, 333.60, 115.60, 116.20,  
237.90, 445.25, 337.00, 423.60, 261.20, 275.00, 103.60,  
465.30, 308.25, 259.70, 244.66, 229.61, 214.57, 199.53, 184.48,
```

```
169.44)
```

```
Precipit_Abr <- c(69.90, 93.90, 182.00, 199.70, 163.30, 107.80,  
214.50, 250.80, 256.55, 124.65, 260.35, 334.60, 352.20, 137.80,  
259.64, 263.69, 267.74, 271.78, 275.83, 279.88, 283.93)
```

```
Precipit_Jul <- c(0.00, 1.00, 3.30, 2.80, 5.90, 2.40, 4.60, 11.70,  
11.95, 6.50, 25.30, 45.60, 65.90, 7.50, 44.40, 49.30, 54.19,  
59.08, 63.98, 68.87, 73.76)
```

```
Precipit_Ago <- c(0.10, 0.00, 0.00, 0.70, 1.10, 0.60, 15.35,  
7.60, 30.25, 5.70, 6.40, 3.00, 3.20, 5.20, 0.26, -1.81, -3.88,  
-5.96, -8.03, -10.10, -12.18)
```

```
Precipit_Sep <- c(26.20, 1.20, 0.00, 0.50, 49.50, 0.20, 7.10,  
2.20, 16.75, 1.55, 15.95, 8.30, 6.30, 0.53, 5.38, 4.95, 4.52, 4.08,  
3.65, 3.22, 2.78)
```

```
Precipit_Oct <- c(0.00, 0.00, 65.90, 13.00, 31.20, 14.70, 3.65,  
12.60, 41.55, 9.60, 9.45, 10.85, 26.00, 31.98, 27.48, 29.54,  
31.60, 33.66, 35.72, 37.79, 39.85)
```

```
Precipit_Dic <- c(33.80, 15.80, 72.10, 54.70, 51.90, 92.40,  
102.00, 53.55, 32.80, 20.10, 210.65, 162.60, 34.50, 114.82,  
122.15, 128.99, 135.83, 142.67, 149.51, 156.34, 163.18)
```

```
Temp_Mar <- c(14.10, 14.30, 14.60, 14.60, 15.00, 15.20, 19.80,  
18.13, 18.90, 19.00, 19.75, 18.85, 19.45, 19.65, 21.07, 21.58,  
22.09, 22.60, 23.11, 23.63, 24.14)
```

```
Temp_Abr <- c(14.15, 14.60, 14.30, 14.50, 14.90, 15.50, 19.75,
19.50, 19.30, 19.10, 19.85, 19.15, 19.50, 19.35, 21.29, 21.28,
21.80, 22.32, 22.84, 23.36, 23.88)
```

```
Temp_May <- c(14.20, 14.30, 14.30, 14.30, 14.70, 14.40,
18.75, 18.90, 18.60, 18.60, 24.40, 18.75, 19.25, 18.65, 21.50,
22.06, 22.62, 23.18, 23.75, 24.31, 24.87)
```

```
Temp_Jul <- c(12.70, 13.80, 13.70, 13.40, 13.10, 13.90, 17.45,
17.50, 22.20, 17.80, 17.80, 18.00, 12.90, 21.50, 19.79, 20.28,
20.77, 21.26, 21.75, 22.24, 22.73)
```

```
Temp_Ago <- c(13.90, 14.00, 13.40, 13.40, 14.00, 14.00, 18.05,
17.10, 22.00, 17.50, 17.60, 17.35, 13.30, 17.60, 1 8 . 3 5 ,
18.67, 18.99, 19.31, 19.63, 19.95, 20.27)
```

```
Temp_Sep <- c(25.28, 24.94, 25.29, 24.92, 25.25, 24.93, 25.06,
24.89, 25.35, 25.10, 24.73, 25.20, 25.00, 24.92, 24.97, 24.95,
24.94, 24.93, 24.91, 24.90, 24.89)
```

```
Temp_Oct <- c(13.40, 14.20, 13.30, 15.50, 14.40, 15.40, 18.10,
21.30, 22.20, 18.10, 17.90, 18.75, 13.10, 19.23, 19.61, 19.98,
20.36, 20.74, 21.11, 21.49, 21.87)
```

```
modelo <- lm(Superficie_cosechada ~ Ventas + Precipit_Ene
+ Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_Jul
+ Precipit_Ago + Precipit_Sep + Precipit_Oct + Precipit_Dic
+ Temp_Mar + Temp_Abr + Temp_May + Temp_Jul + Temp_
Ago + Temp_Sep + Temp_Oct, data = Banano_Bolivar)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Superficie_cosechada, type= 'o', col="black", xaxt="n",
lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano en Provincia Bolívar (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie cosechada
(Ha)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Ene, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type='o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type='o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jul, type='o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Superficie_cosechada, type='o', col="black", xaxt="n",
lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ago, type='b', lwd=2, axes=FALSE, main =
"Producción de banano en Provincia Bolívar (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie cosechada
(Ha)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Sep, type='b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Oct, type='o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Dic, type='o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Mar, type='o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Abr, type='o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Superficie_cosechada, type='o', col="black", xaxt="n",
lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)

plot(Temp_May, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano en Provincia Bolívar (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie cosechada
(Ha)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)

plot(Temp_Jul, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)

plot(Temp_Ago, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)

plot(Temp_Sep, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)

plot(Temp_Oct, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Dic, type= 'o', lwd=2, axes=FALSE,
col="darkslategray1", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
getwd()
```

```
library(readxl)
```

```
Banano_Guayas <- read_excel("G:/Libros para Ingeniería/  
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram  
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos  
ESPAC 2000 a 2019/Banano.Guayas.xlsx")
```

```
View(Banano_Guayas)
```

```
str(Banano_Guayas)
```

```
names(Banano_Guayas)
```

```
cor(Banano_Guayas)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",  
"2005", "2006", "2007", "2008", "2009", "2010", "2011",  
"2012", "2013", "2014", "2015", "2016", "2017", "2018",  
"2019", "2020")
```

```
V <- c(1:21)
```

```
Ventas <- c(9014, 9720, 1742, 12131, 14929, 14867, 24230,  
17064, 9819, 9705, 7279, 13663, 19042, 14095, 34842, 33175,  
19673, 5320, 21726, 22433, 23139)
```

```
Precipit_Feb <- c(133.40, 75.00, 104.50, 164.00, 212.60, 125.60,  
507.10, 441.40, 418.55, 298.45, 355.95, 211.85, 355.50, 355.70,  
258.14, 233.71, 209.28, 184.86, 160.43, 136.00, 111.58)
```

```
Precipit_Jun <- c(15.00, 0.90, 2.00, 41.10, 6.50, 5.10, 19.40,  
48.00, 34.90, 25.90, 34.55, 46.15, 14.00, 30.20, 28.85, 28.23,  
27.61, 26.99, 26.38, 25.76, 25.14)
```

```
Precipit_Sep <- c(26.20, 1.20, 0.00, 0.50, 49.50, 0.20, 7.10,  
2.20, 16.75, 1.55, 15.95, 8.30, 6.30, 0.53, 5.38, 4.95, 4.52, 4.08,  
3.65, 3.22, 2.78)
```

```
Temp_Mar <- c(14.10, 14.30, 14.60, 14.60, 15.00, 15.20, 19.80,
18.13, 18.90, 19.00, 19.75, 18.85, 19.45, 19.65, 21.07, 21.58,
22.09, 22.60, 23.11, 23.63, 24.14)
```

```
modelo <- lm(Produccion ~ Ventas + Precipit_Feb + Precipit_
May + Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_
Sep + Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_
Ene + Temp_Feb + Temp_Mar + Temp_Abr + Temp_May +
Temp_Jun + Temp_Jul + Temp_Ago + Temp_Sep + Temp_Oct
+ Temp_Nov + Temp_Dic, data = Banano_Guayas)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano en Provincia Guayas (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Producción (Ton)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Sep, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Mar, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
getwd()
```

```
library(readxl)
```

```
Banano_LosRios <- read_excel("G:/Libros para Ingeniería/
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos
```

```
ESPAC 2000 a 2019/Banano.LosRios.xlsx")
```

```
View(Banano_LosRios)
```

```
str(Banano_LosRios)
```

```
names(Banano_LosRios)
```

```
cor(Banano_LosRios)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",
"2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "2018",
"2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(2054954, 2066211, 2077467, 2270973,
2290433, 2257812, 2273532, 2179639, 2421374, 3744583,
3887126, 2670049, 2753724, 1729216, 3532359, 2574844,
2822585, 2327758, 2472546, 2975190, 3019745)
```

```
Superficie_cosechada <- c(51788, 51996, 52203, 53723,
50118, 49291, 50648, 50450, 52721, 62046, 63975, 55040,
62536, 53267, 82301, 52123, 61937, 50278, 55168, 62087,
62736)
```

```
Superficie_plantada <- c(52911, 53307, 53703, 54426, 51159,
50402, 52347, 53438, 57994, 65285, 67934, 57857, 63866,
72838, 85154, 53741, 62710, 52249, 56324, 67158, 68021)
```

```
Ventas <- c(1796590, 1857778, 1698550, 2004954, 1757514,
2033671, 1992145, 1950380, 2252980, 3105518, 3446460,
2523171, 2608488, 1686831, 3444209, 2526721, 2762903,
2251421, 1910768, 1576550, 1242332)
```

```
Temp_Sep <- c(8.14, 9.50, 10.86, 12.22, 13.58, 14.94, 16.30,
17.66, 25.80, 2.00, 15.50, 63.60, 1.80, 25.82, 27.18, 28.54,
29.90, 31.26, 32.62, 33.98, 35.34)
```

```
Temp_Oct <- c(32.24, 30.20, 28.16, 26.12, 24.08, 22.04, 20.00,
17.96, 20.70, 11.20, 6.00, 10.40, 10.90, 5.72, 3.68, 1.64, -0.40,
-2.44, -4.48, -6.52, -8.56)
```

```
Temp_Nov <- c(58.70, 52.30, 45.90, 39.50, 33.10, 26.70, 20.30,
13.90, 7.50, 1.10, 17.50, 7.80, 24.30, 23.73, 27.76, 31.79, 35.82,
39.85, 43.88, 47.91, 51.94)
```

```
modelo <- lm(Superficie_cosechada ~ Produccion + Superficie_
plantada + Ventas + Temp_Sep + Temp_Oct + Temp_Nov, data
= Banano_LosRios)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Superficie_cosechada, type= 'o', col="black", xaxt="n",
lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Produccion, type= 'b', lwd=2, axes=FALSE, main =
"Producción de banano en Provincia Guayas (Musa sp): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie cosechada
(Ha)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Sep, type= 'o', lwd=2, axes=FALSE, col="violet",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Oct, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Nov, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
grid(col="black", lwd=0.05)
```

1.1.2 Ejemplo 3. “Cacao.Nacional”

```
getwd()
```

```
library(readxl)
```

```
Cacao_Nacional <- read_excel("G:/Libros para Ingeniería/
Regresión lineal para ingeniería. Excel, R, SAS, Wolfram
System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos
ESPAC 2000 a 2019/Cacao.Nacional.xlsx")
```

```
View(Cacao_Nacional)
```

```
str(Cacao_Nacional)
```

```
names(Cacao_Nacional)
```

cor(Cacao_Nacional)

modelo <- lm(Produccion ~ Superficie_plantada + Semilla_comun + Semilla_mejorada + Semilla_HN + Semilla_HI + Riego + Superficie_cosechada + Sequia + Helada + Plagas + Enfermedades + Inundacion + Otras_causas + Aplicacion_Fertilizantes + Aplicacion_Fitosanitarios + Ventas + Precios_Prod_Pond_CCN51_Ene + Precios_Prod_Pond_CCN51_Feb + Precios_Prod_Pond_CCN51_Mar + Precios_Prod_Pond_CCN51_Abr + Precios_Prod_Pond_CCN51_May + Precios_Prod_Pond_CCN51_Jun + Precios_Prod_Pond_CCN51_Jul + Precios_Prod_Pond_CCN51_Ago + Precios_Prod_Pond_CCN51_Sep + Precios_Prod_Pond_CCN51_Oct + Precios_Prod_Pond_CCN51_Nov + Precios_Prod_Pond_CCN51_Dic + Pre_Cac_FiAroma_Ene + Pre_Cac_FiAroma_Feb + Pre_Cac_FiAroma_Mar + Pre_Cac_FiAroma_Abr + Pre_Cac_FiAroma_May + Pre_Cac_FiAroma_Jun + Pre_Cac_FiAroma_Jul + Pre_Cac_FiAroma_Ago + Pre_Cac_FiAroma_Sep + Pre_Cac_FiAroma_Oct + Pre_Cac_FiAroma_Nov + Pre_Cac_FiAroma_Dic + Fosfato_diam_Fert_Ene + Fosfato_diam_Fert_Feb + Fosfato_diam_Fert_Mar + Fosfato_diam_Fert_Abr + Fosfato_diam_Fert_May + Fosfato_diam_Fert_Jun + Fosfato_diam_Fert_Jul + Fosfato_diam_Fert_Ago + Fosfato_diam_Fert_Sep + Fosfato_diam_Fert_Oct + Fosfato_diam_Fert_Nov + Fosfato_diam_Fert_Dic + Muriato_K_Fert_Ene + Muriato_K_Fert_Feb + Muriato_K_Fert_Mar + Muriato_K_Fert_Abr + Muriato_K_Fert_May + Muriato_K_Fert_Jun + Muriato_K_Fert_Jul + Muriato_K_Fert_Ago + Muriato_K_Fert_Sep + Muriato_K_Fert_Oct + Muriato_K_Fert_Nov + Muriato_K_Fert_Dic + Urea_Fert_Ene + Urea_Fert_Feb + Urea_Fert_Mar + Urea_Fert_Abr + Urea_Fert_May + Urea_Fert_Jun + Urea_Fert_Jul + Urea_Fert_Ago + Urea_Fert_Sep + Urea_Fert_Oct + Urea_Fert_Nov + Urea_Fert_Dic + Propiconazol_Fungi_Ene + Propiconazol_Fungi_Feb + Propiconazol_Fungi_Mar + Propiconazol_Fungi_Abr + Propiconazol_Fungi_May + Propiconazol_Fungi_Jun + Propiconazol_Fungi_Jul + Propiconazol_Fungi_Ago + Propiconazol_Fungi_Sep + Propiconazol_Fungi_Oct + Propiconazol_Fungi_Nov + Propiconazol_Fungi_Dic + Cimo_Manco_Fungi_Ene + Cimo_Manco_Fungi_Feb + Cimo_Manco_Fungi_Mar + Cimo_Manco_Fungi_Abr + Cimo_Manco_Fungi_May + Cimo_Manco_Fungi_Jun + Cimo_Manco_Fungi_Jul + Cimo_Manco_Fungi_Ago + Cimo_Manco_Fungi_Sep + Cimo_Manco_Fungi_Oct + Cimo_Manco_Fungi_Nov + Cimo_Manco_Fungi_Dic + Carbendazim_Fungi_Ene + Carbendazim_Fungi_Feb + Carbendazim_Fungi_Mar + Carbendazim_Fungi_Abr + Carbendazim_Fungi_May + Carbendazim_Fungi_Jun + Carbendazim_Fungi_Jul + Carbendazim_Fungi_Ago + Carbendazim_Fungi_Sep + Carbendazim_Fungi_Oct + Carbendazim_Fungi_Nov + Carbendazim_Fungi_Dic + Clorotalonil_Fungi_Ene + Clorotalonil_Fungi_Feb + Clorotalonil_Fungi_Mar + Clorotalonil_Fungi_Abr + Clorotalonil_Fungi_May + Clorotalonil_Fungi_Jun + Clorotalonil_Fungi_Jul + Clorotalonil_Fungi_Ago + Clorotalonil_Fungi_Sep + Clorotalonil_Fungi_Oct + Clorotalonil_Fungi_Nov + Clorotalonil_Fungi_Dic + Glifosato_Herbi_Ene + Glifosato_Herbi_Feb + Glifosato_Herbi_Mar + Glifosato_Herbi_Abr

+ Glifosato_Herbi_May + Glifosato_Herbi_Jun + Glifosato_Herbi_Jul + Glifosato_Herbi_Ago + Glifosato_Herbi_Sep + Glifosato_Herbi_Oct + Glifosato_Herbi_Nov + Glifosato_Herbi_Dic + Paraquat_Herbi_Ene + Paraquat_Herbi_Feb + Paraquat_Herbi_Mar + Paraquat_Herbi_Abr + Paraquat_Herbi_May + Paraquat_Herbi_Jun + Paraquat_Herbi_Jul + Paraquat_Herbi_Ago + Paraquat_Herbi_Sep + Paraquat_Herbi_Oct + Paraquat_Herbi_Nov + Paraquat_Herbi_Dic + Pendimetalina_Herbi_Ene + Pendimetalina_Herbi_Feb + Pendimetalina_Herbi_Mar + Pendimetalina_Herbi_Abr + Pendimetalina_Herbi_May + Pendimetalina_Herbi_Jun + Pendimetalina_Herbi_Jul + Pendimetalina_Herbi_Ago + Pendimetalina_Herbi_Sep + Pendimetalina_Herbi_Oct + Pendimetalina_Herbi_Nov + Pendimetalina_Herbi_Dic + Propanil_Herbi_Ene + Propanil_Herbi_Feb + Propanil_Herbi_Mar + Propanil_Herbi_Abr + Propanil_Herbi_May + Propanil_Herbi_Jun + Propanil_Herbi_Jul + Propanil_Herbi_Ago + Propanil_Herbi_Sep + Propanil_Herbi_Oct + Propanil_Herbi_Nov + Propanil_Herbi_Dic + Dos_Cuatro_Damina_Herbi_Ene + Dos_Cuatro_Damina_Herbi_Feb + Dos_Cuatro_Damina_Herbi_Mar + Dos_Cuatro_Damina_Herbi_Abr + Dos_Cuatro_Damina_Herbi_May + Dos_Cuatro_Damina_Herbi_Jun + Dos_Cuatro_Damina_Herbi_Jul + Dos_Cuatro_Damina_Herbi_Ago + Dos_Cuatro_Damina_Herbi_Sep + Dos_Cuatro_Damina_Herbi_Oct + Dos_Cuatro_Damina_Herbi_Nov + Dos_Cuatro_Damina_Herbi_Dic + Atrazina_Herbi_Ene + Atrazina_Herbi_Feb + Atrazina_Herbi_Mar + Atrazina_Herbi_Abr + Atrazina_Herbi_May + Atrazina_Herbi_Jun + Atrazina_Herbi_Jul + Atrazina_Herbi_Ago + Atrazina_Herbi_

Sep + Atrazina_Herbi_Oct + Atrazina_Herbi_Nov + Atrazina_Herbi_Dic + Clorpiriphos_Insect_Ene + Clorpiriphos_Insect_Feb + Clorpiriphos_Insect_Mar + Clorpiriphos_Insect_Abr + Clorpiriphos_Insect_May + Clorpiriphos_Insect_Jun + Clorpiriphos_Insect_Jul + Clorpiriphos_Insect_Ago + Clorpiriphos_Insect_Sep + Clorpiriphos_Insect_Oct + Clorpiriphos_Insect_Nov + Clorpiriphos_Insect_Dic + Cipermetrina_Insect_Ene + Cipermetrina_Insect_Feb + Cipermetrina_Insect_Mar + Cipermetrina_Insect_Abr + Cipermetrina_Insect_May + Cipermetrina_Insect_Jun + Cipermetrina_Insect_Jul + Cipermetrina_Insect_Ago + Cipermetrina_Insect_Sep + Cipermetrina_Insect_Oct + Cipermetrina_Insect_Nov + Cipermetrina_Insect_Dic + I_Gini_Rural_ISem + I_Gini_Rural_IISem + I_Gini_Nacional_ISem + I_Gini_Nacional_IISem + Credito_Agro_Ene + Credito_Agro_Feb + Credito_Agro_Mar + Credito_Agro_Abr + Credito_Agro_May + Credito_Agro_Jun + Credito_Agro_Jul + Credito_Agro_Ago + Credito_Agro_Sep + Credito_Agro_Oct + Credito_Agro_Nov + Credito_Agro_Dic + Empl_Tot_ITrim + Empl_Tot_IITrim + Empl_Tot_IIITrim + Empl_Tot_IVTrim + Empl_Agrop_ITrim + Empl_Agrop_IITrim + Empl_Agrop_IIITrim + Empl_Agrop_IVTrim + Tasa_empl_adec_Rural_ITrim + Tasa_empl_adec_Rural_IITrim + Tasa_empl_adec_Rural_IIITrim + Tasa_empl_adec_Rural_IVTrim + Tasa_sub_empl_adec_Rural_ITrim + Tasa_sub_empl_adec_Rural_IITrim + Tasa_sub_empl_adec_Rural_IIITrim + Tasa_sub_empl_adec_Rural_IVTrim + Tasa_otro_empl_no_pleno_Rural_ITrim + Tasa_otro_empl_no_pleno_Rural_IITrim + Tasa_otro_empl_no_pleno_Rural_IIITrim + Tasa_otro_empl_

```

no_pleno_Rural_IVTrim + Tasa_empl_no_remun_Rural_
ITrim + Tasa_empl_no_remun_Rural_IITrim + Tasa_empl_no_
remun_Rural_IITrim + Tasa_empl_no_remun_Rural_IVTrim +
Tasa_desem_adecuado_Rural_ITrim + Tasa_desem_adecuado_
Rural_IITrim + Tasa_desem_adecuado_Rural_IITrim + Tasa_
desem_adecuado_Rural_IVTrim + Pob_ingresos_Rural_ISem
+ Pob_ingresos_Rural_IISem + Pob_extrem_ingresos_Rural_
ISem + Pob_extrem_ingresos_Rural_IITSem + IPA + TPA +
TPIAR + TVAA + IPP_N_Ene + IPP_N_Feb + IPP_N_Mar +
IPP_N_Abr + IPP_N_May + IPP_N_Jun + IPP_N_Jul + IPP_N_
Ago + IPP_N_Sep + IPP_N_Oct + IPP_N_Nov + IPP_N_Dic
+ IPP_X_Ene + IPP_X_Feb + IPP_X_Mar + IPP_X_Abr
+ IPP_X_May + IPP_X_Jun + IPP_X_Jul + IPP_X_Ago +
IPP_X_Sep + IPP_X_Oct + IPP_X_Nov + IPP_X_Dic + IPM_
Ene + IPM_Feb + IPM_Mar + IPM_Abr + IPM_May + IPM_
Jun + IPM_Jul + IPM_Ago + IPM_Sep + IPM_Oct + IPM_Nov
+ IPM_Dic + IPX_Ene + IPX_Feb + IPX_Mar + IPX_Abr +
IPX_May + IPX_Jun + IPX_Jul + IPX_Ago + IPX_Sep + IPX_
Oct + IPX_Nov + IPX_Dic + IPI_Ene + IPI_Feb + IPI_Mar +
IPI_Abr + IPI_May + IPI_Jun + IPI_Jul + IPI_Ago + IPI_Sep
+ IPI_Oct + IPI_Nov + IPI_Dic + IPF_Ene + IPF_Feb + IPF_
Mar + IPF_Abr + IPF_May + IPF_Jun + IPF_Jul + IPF_Ago +
IPF_Sep + IPF_Oct + IPF_Nov + IPF_Dic + IBC_Ene + IBC_
Feb + IBC_Mar + IBC_Abr + IBC_May + IBC_Jun + IBC_Jul
+ IBC_Ago + IBC_Sep + IBC_Oct + IBC_Nov + IBC_Dic +
IPCA_Ene + IPCA_Feb + IPCA_Mar + IPCA_Abr + IPCA_
May + IPCA_Jun + IPCA_Jul + IPCA_Ago + IPCA_Sep +
IPCA_Oct + IPCA_Nov + IPCA_Dic + Inf_Men_Ene + Inf_
Men_Feb + Inf_Men_Mar + Inf_Men_Abr + Inf_Men_May +

```

```

Inf_Men_Jun + Inf_Men_Jul + Inf_Men_Ago + Inf_Men_Sep
+ Inf_Men_Oct + Inf_Men_Nov + Inf_Men_Dic + Precipit_Ene
+ Precipit_Feb + Precipit_Mar + Precipit_Abr + Precipit_May
+ Precipit_Jun + Precipit_Jul + Precipit_Ago + Precipit_Sep
+ Precipit_Oct + Precipit_Nov + Precipit_Dic + Temp_Ene +
Temp_Feb + Temp_Mar + Temp_Abr + Temp_May + Temp_
Jun + Temp_Jul + Temp_Ago + Temp_Sep + Temp_Oct +
Temp_Nov + Temp_Dic, data = Cacao_Nacional)

```

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

También, se pueden ingresar variables de interés así:

```

Anualidad <- c("2000", "2001", "2002", "2003", "2004",
"2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "2018",
"2019", "2020")

```

V <- c(1:21)

```

Produccion <- c(64991, 62630, 60268, 88263, 89680, 93659,
87562, 85890, 94300, 120582, 132100, 163152, 133323,
128446, 156216, 180192, 177551, 205955, 286704, 64992,
64992)

```

```
Superficie_cosechada <- c(402836, 383206, 363575, 348434,
336358, 357706, 350028, 356657, 376604, 398104, 360025,
399467, 390176, 402434, 372637, 432094, 454257, 467327,
464546, 402837, 402837)
```

```
Superficie_plantada <- c(434418, 409065, 383711, 374045,
366927, 406866, 407868, 422985, 455414, 468840, 470054,
521091, 507721, 508885, 461030, 537410, 559617,
573516, 464546, 434419, 434419)
```

```
Semilla_comun <- c(415286, 386639, 357991, 358350, 334011,
374747, 357289, 339290, 238616, 351893, 327969, 342422,
308388, 321677, 260253, 271345, 273106, 256715, 415287,
338312, 261337)
```

```
Semilla_mejorada <- c(19132, 22427, 25721, 15694, 32915,
32119, 39160, 54016, 125889, 92757, 106590, 128941, 155346,
144129, 153939, 215342, 217946, 208212, 19133, 125052,
230971)
```

```
Semilla_HN <- c(0, 0, 0, 0, 0, 0, 11420, 28590, 31124, 22971,
33524, 45958, 42656, 40999, 44402, 49184, 66409, 108467,
81549, 87356, 93162)
```

```
Semilla_HI <- c(0, 0, 0, 0, 0, 0, 1088, 3008, 1220, 1971,
3770, 1331, 2079, 2436, 1540, 2155, 122, 1445, 1371, 1298)
```

```
Riego <- c(33345, 32761, 32176, 36899, 35343, 55539, 64295,
83989, 74560, 90426, 107687, 116366, 115201, 112282, 99038,
```

```
116389, 138556, 125203, 33346, 89513, 145679)
```

```
Helada <- c(843, 422, 0, 351, 0, 351, 636, 1967, 2632, 539,
5103, 4731, 3189, 3176, 892, 2564, 1753, 766, 844, 1033,
808)
```

```
Precipit_Abr <- c(128.48, 197.73, 272.33, 91.81, 169.76,
300.08, 49.02, 201.92, 272.56, 82.75, 254.54, 361.61, 243.33,
180.22, 123.13, 202.39, 182.51, 284.35, 136.42, 228.96,
253.08)
```

```
Precipit_Jul <- c(2.27, 2.85, 4.23, 9.83, 2.68, 0.80, 2.59, 5.20,
2.46, 1.15, 27.84, 39.07, 6.07, 11.80, 12.50, 29.78, 19.04, 13.49,
14.70, 17.80, 17.92)
```

```
Precios_Prod_Pond_CCN51_Ene <- c(132.23, 129.63, 127.02,
124.41, 121.80, 119.20, 116.59, 113.98, 111.37, 108.77, 106.16,
103.55, 100.94, 86.76, 94.43, 107.20, 106.08, 81.44, 71.19,
86.51, 80.08)
```

```
Precios_Prod_Pond_CCN51_Mar <- c(136.43, 133.82, 131.21,
128.60, 125.99, 123.38, 120.77, 118.16, 115.55, 112.94, 110.33,
107.72, 105.11, 82.80, 115.58, 105.59, 109.45, 71.34, 93.16,
84.80, 84.24)
```

```
Precios_Prod_Pond_CCN51_May <- c(119.79, 118.43, 117.08,
115.72, 114.36, 113.01, 111.65, 110.29, 108.94, 107.58, 106.22,
104.87, 103.51, 88.89, 105.09, 112.42, 114.51, 69.65, 106.39,
89.62, 92.66)
```

```
Precios_Prod_Pond_CCN51_Jun <- c(144.47, 141.58, 138.69,
135.81, 132.92, 130.03, 127.15, 124.26, 121.37, 118.48, 115.60,
112.71, 109.82, 88.57, 110.09, 119.37, 116.55, 71.87, 91.85,
89.61, 86.73)
```

```
Precios_Prod_Pond_CCN51_Jul <- c(160.19, 156.41, 152.62,
148.84, 145.05, 141.27, 137.48, 133.70, 129.91, 126.13,
122.34, 118.56, 114.77, 85.73, 119.93, 125.77, 116.89, 69.64,
91.19, 88.28, 84.49)
```

```
Precios_Prod_Pond_CCN51_Ago <- c(191.18, 185.31, 179.44,
173.57, 167.70, 161.83, 155.96, 150.09, 144.22, 138.35,
132.48, 126.61, 120.74, 88.03, 128.25, 115.43, 118.70, 68.80,
81.96, 79.65, 73.78)
```

```
Pre_Cac_FiAroma_Ene <- c(140.30, 137.32, 134.34, 131.36,
128.37, 125.39, 122.41, 119.43, 116.45, 113.46, 110.48, 107.50,
104.52, 89.09, 103.99, 101.49, 110.85, 82.21, 70.42, 90.06,
80.66)
```

```
Pre_Cac_FiAroma_Feb <- c(142.14, 138.94, 135.74, 132.54,
129.34, 126.14, 122.94, 119.74, 116.54, 113.34, 110.14, 106.94,
103.74, 84.50, 109.58, 101.34, 106.15, 70.92, 78.75, 85.32,
78.14)
```

```
Pre_Cac_FiAroma_Mar <- c(130.54, 128.30, 126.06, 123.82,
121.58, 119.34, 117.10, 114.86, 112.62, 110.38, 108.14, 105.90,
103.66, 83.23, 115.24, 103.22, 108.75, 71.00, 94.61, 86.81,
85.74)
```

```
Pre_Cac_FiAroma_Abr <- c(120.25, 118.73, 117.22, 115.70,
114.19, 112.67, 111.16, 109.64, 108.12, 106.61, 105.09, 103.58,
102.06, 85.30, 112.19, 104.77, 108.20, 70.35, 101.31, 89.88,
89.94)
```

```
Pre_Cac_FiAroma_May <- c(122.60, 121.06, 119.53, 117.99,
116.45, 114.92, 113.38, 111.84, 110.31, 108.77, 107.23, 105.70,
104.16, 84.18, 113.84, 110.15, 113.12, 72.05, 102.98, 89.78,
91.87)
```

```
Pre_Cac_FiAroma_Jun <- c(151.82, 148.52, 145.22, 141.92,
138.62, 135.32, 132.02, 128.72, 125.41, 122.11, 118.81, 115.51,
112.21, 89.90, 116.79, 117.34, 113.33, 72.24, 94.33, 89.10,
85.80)
```

```
I_Gini_Rural_ISem <- c(0.47, 0.47, 0.47, 0.46, 0.46, 0.46,
0.46, 0.48, 0.47, 0.47, 0.46, 0.43, 0.43, 0.46, 0.44, 0.45, 0.43,
0.45, 0.50, 0.53)
```

```
I_Gini_Rural_IISem <- c(0.49, 0.49, 0.48, 0.48, 0.48, 0.48,
0.47, 0.50, 0.48, 0.45, 0.44, 0.46, 0.46, 0.44, 0.44, 0.47, 0.46,
0.46, 0.44, 0.44, 0.44)
```

```
I_Gini_Nacional_ISem <- c(0.53, 0.53, 0.52, 0.52, 0.51, 0.51,
0.50, 0.50, 0.53, 0.52, 0.52, 0.50, 0.47, 0.46, 0.49, 0.46, 0.46,
0.46, 0.47, 0.55, 0.57)
```

```
Credito_Agro_Ene <- c(0.00 , 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 91400.20, 740371.39,
```

```
1389342.57,   2300073.20,   2163766.06,   3598015.57,
3985227.31, 4634198.50)
```

```
Credito_Agro_Feb <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 6387084.07, 6183528.21,
5979972.35,   4706511.90,   7712669.81,   4299400.18,
5165748.91, 4962193.05)
```

```
Credito_Agro_Mar <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, -4633604.52, -2218798.86,
196006.81, 3385244.18, 3476754.73, 8214855.51, 9855229.47,
12270035.14)
```

```
Credito_Agro_Abr <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 2438013.40, 2795478.68,
3152943.96,   3883636.43,   3121420.15,   4598566.99,
4582805.08, 4940270.36)
```

```
Credito_Agro_May <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 451888.85, 1332219.65,
2212550.45,   2396333.25,   5366308.06,   4156994.85,
5733873.65, 6614204.45)
```

```
Credito_Agro_Jun <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 5198497.00, 5559624.75,
5920752.49,   5003799.89,   9199168.67,   5726055.38,
7365263.47, 7726391.22)
```

```
Credito_Agro_Jul <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
```

```
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 4700.00,
2175746.46,   5466738.90,   5678809.93,   8409829.38,
10441161.60)
```

```
Credito_Agro_Ago <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 10750.00,
3308657.40,   5142438.20,   5161225.47,   4213314.69,
6390008.43)
```

```
Credito_Agro_Sep <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 16800.00,
11273007.73,   6365969.57,   4848925.52,   16800.00,
1071885.40)
```

```
Credito_Agro_Oct <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00,
25300.00, 3492616.19, 5709882.42, 9517719.43, 25300.00,
12265175.92)
```

```
Empl_Tot_ITrim <- c(4261886, 4454182, 4646479, 4838775,
5031071, 5223368, 5415664, 5607960, 6005394, 6125135,
6113230, 6304834, 6424840, 6664241, 6706314, 7091116,
7412671, 7728968, 7802374, 7915516, 8107812)
```

```
Empl_Tot_IITrim <- c(5639186, 5754935, 5870684, 5986432,
6102181, 6217930, 6045262, 5872593, 6245225, 6209683,
6174141, 6224584, 6588271, 6725795, 6643458, 7098584,
7415099, 7781560, 7648773, 6245225, 6245225)
```

```
Inf_Men_Ene <- c(0.02, 0.02, 0.02, 0.01, 0.01, 0.01, 0.01, 0.00,
0.02, 0.01, 0.02, 0.01, 0.00, 0.01, 0.02, 0.00, 0.00, 0.00,
0.01, 0.01)
```

```
Inf_Men_Feb <- c(0.02, 0.01, 0.01, 0.01, 0.01, 0.01, 0.02, 0.00,
0.02, 0.00, 0.01, 0.01, 0.00, 0.00, 0.00, 0.01, 0.00, 0.00,
0.00, 0.00)
```

```
Inf_Men_Abr <- c(0.01, 0.01, 0.01, 0.01, 0.01, 0.02, -0.01,
0.00, 0.03, 0.01, 0.01, 0.01, 0.00, 0.00, 0.01, 0.02, 0.01, 0.01,
-0.01, 0.00, 0.00)
```

```
Inf_Men_Jun <- c(0.00, 0.00, 0.00, 0.00, 0.00, 0.00, -0.01,
0.01, 0.01, -0.01, 0.00, -0.01, 0.00, 0.00, 0.00, 0.00,
-0.01, 0.00, 0.00)
```

```
Inf_Men_Jul <- c(0.00, 0.00, 0.00, 0.00, 0.00, -0.01, 0.00, 0.01,
0.01, 0.00, 0.00, 0.00, -0.01, 0.01, 0.00, 0.00, -0.01, 0.00,
0.00, 0.00)
```

```
Inf_Men_Sep <- c(0.01, 0.01, 0.01, 0.01, 0.01, 0.01, 0.01, 0.01,
0.01, 0.00, 0.00, 0.01, 0.02, 0.01, 0.00, 0.00, 0.00, -0.01, 0.00,
0.00, 0.00)
```

```
Aplicacion_Fertilizantes <- c(31859, 36927, 41994, 41266,
52759, 58683, 79836, 106118, 122356, 146846, 171199,
225080, 209606, 129856, 143179, 178714, 191023, 217847,
31860, 131633, 231406)
```

```
Fosfato_diam_Fert_Ene <- c(70.59, 68.37, 66.15, 63.93, 61.72,
59.50, 57.28, 55.07, 52.85, 50.63, 48.42, 46.20, 43.98, 43.36,
38.55, 37.56, 35.41, 30.60, 28.88, 31.43, 26.25)
```

```
Fosfato_diam_Fert_Mar <- c(72.10, 69.80, 67.49, 65.18, 62.88,
60.57, 58.26, 55.96, 53.65, 51.35, 49.04, 46.73, 44.43, 42.75, 40.34, 37.55, 35.61, 29.53, 29.44, 31.17, 25.98)
```

```
Fosfato_diam_Fert_Abr <- c(71.07, 68.82, 66.58, 64.33, 62.08,
59.84, 57.59, 55.34, 53.10, 50.85, 48.61, 46.36, 44.11, 42.59, 40.10, 37.52, 35.26, 29.34, 29.98, 31.10, 26.14)
```

```
Muriato_K_Fert_Ene <- c(60.37, 58.23, 56.09, 53.95, 51.81, 49.66, 47.52, 45.38, 43.24, 41.09, 38.95, 36.81, 34.67, 33.72, 30.33, 28.42, 26.02, 20.95, 20.47, 22.79, 17.53)
```

```
Muriato_K_Fert_Abr <- c(61.33, 59.13, 56.94, 54.74, 52.55, 50.35, 48.15, 45.96, 43.76, 41.57, 39.37, 37.17, 34.98, 33.89, 30.79, 28.47, 26.32, 20.26, 20.91, 22.72, 17.41)
```

```
Propiconazol_Fungi_Ene <- c(27.01, 27.05, 27.10, 27.15, 27.20, 27.25, 27.29, 27.34, 27.39, 27.44, 27.49, 27.53, 27.58, 26.18, 28.08, 28.30, 30.44, 26.42, 27.08, 26.33, 27.06)
```

```
Propiconazol_Fungi_Feb <- c(25.71, 25.80, 25.89, 25.98, 26.07, 26.16, 26.26, 26.35, 26.44, 26.53, 26.62, 26.71, 26.80, 26.61, 26.38, 27.43, 28.98, 26.33, 26.97, 27.10, 27.33)
```

```
Propiconazol_Fungi_Mar <- c(32.99, 32.63, 32.28, 31.92,
31.56, 31.21, 30.85, 30.50, 30.14, 29.79, 29.43, 29.08, 28.72,
28.53, 27.27, 28.69, 27.25, 26.07, 27.05, 27.04, 26.34)
```

```
Propiconazol_Fungi_Oct <- c(29.00, 28.89, 28.79, 28.68,
28.58, 28.47, 28.37, 28.26, 28.16, 28.06, 27.95, 27.85, 27.74,
26.35, 27.27, 30.74, 26.07, 27.27, 26.55, 27.01, 26.91)
```

```
Propiconazol_Fungi_Nov <- c(31.49, 31.26, 31.03, 30.79,
30.56, 30.33, 30.09, 29.86, 29.63, 29.40, 29.16, 28.93, 28.70,
27.21, 27.84, 31.95, 25.92, 27.19, 27.18, 27.07, 26.83)
```

```
Propiconazol_Fungi_Dic <- c(31.11, 30.86, 30.61, 30.35,
30.10, 29.85, 29.60, 29.34, 29.09, 28.84, 28.59, 28.34, 28.08,
27.63, 27.90, 27.78, 26.07, 27.17, 26.65, 26.32, 26.07)
```

```
modelo<- lm(Produccion ~ Superficie_cosechada + Superficie_
plantada + Semilla_comun + Semilla_mejorada + Semilla_HN
+ Semilla_HI + Riego + Helada, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA<- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Superficie_cosechada, type= 'o', col="black", xaxt="n",
lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Produccion, type= 'b', lwd=2, axes=FALSE, main =
"Superficie cosechada de cacao (Theobroma cacao): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie anual (Ha)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Semilla_comun, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Semilla_mejorada, type= 'o', lwd=2, axes=FALSE,
col="violet", ann=F)
```

```
par(new=TRUE)
```

```
plot(Semilla_HN, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```

grid(col="black", lwd=0.05)

plot(Superficie_cosechada, type= 'o', col="black", xaxt="n",
lwd=2, ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Semilla_HI, type= 'b', lwd=2, axes=FALSE, main =
"Superficie cosechada de cacao (Theobroma cacao): CNA
(2000) y ESPAC (2002-2020)", ylab = "Superficie anual (Ha)",
xlab="Año productivo", col="red")

```

```

par(new=TRUE)

plot(Riego, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Helada, type= 'o', lwd=2, axes=FALSE, col="yellow",
ann=F)

grid(col="black", lwd=0.05)

```

modelo

plot(modelo)

```

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$transformed

```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Helada ~ Precipit_Abr + Precipit_Jul, data =  
Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Helada, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type= 'b', lwd=2, axes=FALSE, main =  
"Superficie helada en cacao (Theobroma cacao): CNA (2000)  
y ESPAC (2002-2020)", ylab = "Superficie anual (Ha)",  
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Jul, type= 'o', lwd=2, axes=FALSE, col="yellow",  
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ Precios_Prod_Pond_CCN51_Ene
+ Precios_Prod_Pond_CCN51_Mar + Precios_Prod_Pond_
CCN51_May + Precios_Prod_Pond_CCN51_Jun + Precios_
Prod_Pond_CCN51_Jul + Precios_Prod_Pond_CCN51_Ago,
data = Cacao_Nacional)

summary(modelo)

```

```

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Precios_Prod_Pond_CCN51_Ene, type= 'b', lwd=2,
axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")

par(new=TRUE)

plot(Precios_Prod_Pond_CCN51_Jul, type= 'o', lwd=2,
axes=FALSE, col="yellow", ann=F)

par(new=TRUE)

plot(Precios_Prod_Pond_CCN51_Ago, type= 'o', lwd=2,
axes=FALSE, col="cyan", ann=F)

par(new=TRUE)

plot(Precios_Prod_Pond_CCN51_Mar, type= 'o', lwd=2,

```

```
axes=FALSE, col="chartreuse", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo<- lm(Produccion~Pre_Cac_FiAroma_Ene+Pre_Cac_FiAroma_Feb+Pre_Cac_FiAroma_Mar+Pre_Cac_FiAroma_Abr+Pre_Cac_FiAroma_May+Pre_Cac_FiAroma_Jun, data=Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2,
ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Pre_Cac_FiAroma_Ene, type= 'b', lwd=2, axes=FALSE,
main = "Producción de cacao (Theobroma cacao): CNA (2000)
y ESPAC (2002-2020)", ylab = "Producción anual (Ton)",
xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Pre_Cac_FiAroma_May, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Pre_Cac_FiAroma_Abr, type= 'o', lwd=2, axes=FALSE,
col="cyan", ann=F)
```

```
par(new=TRUE)
```

```
plot(Pre_Cac_FiAroma_Jun, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

transformacion.a.normal

w <- transformacion.a.normal\$transformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ I_Gini_Rural_ISem + I_Gini_Rural_IISem + I_Gini_Nacional_ISem, data = Cacao_Nacional)

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(I_Gini_Rural_ISem, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")

par(new=TRUE)

plot(I_Gini_Rural_IISem, type= 'o', lwd=2, axes=FALSE, col="yellow", ann=F)

par(new=TRUE)

plot(I_Gini_Nacional_ISem, type= 'o', lwd=2, axes=FALSE, col="chartreuse", ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Credito_Agro_Ene + Credito_Agro_Feb + Credito_Agro_Mar + Credito_Agro_Abr + Credito_Agro_May + Credito_Agro_Jun + Credito_Agro_Jul + Credito_Agro_Ago + Credito_Agro_Sep + Credito_Agro_Oct, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Feb, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Jul, type= 'o', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Ago, type= 'o', lwd=2, axes=FALSE, col="
yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Ene, type= 'o', lwd=2, axes=FALSE,
col="cyan", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Sep, type= 'o', lwd=2, axes=FALSE,
col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Credito_Agro_Oct, type= 'o', lwd=2, axes=FALSE,
col="orchid", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Empl_Tot_ITrim + Empl_Tot_II-
Trim, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Empl_Tot_ITrim, type= 'b', lwd=2, axes=FALSE, main =
"Producción de cacao (Theobroma cacao): CNA (2000) y ES-
PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="A-
ño productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Empl_Tot_IITrim, type= 'o', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Tasa_sub_empl_adec_Rural_ITrim + Tasa_sub_empl_adec_Rural_IITrim + Tasa_sub_empl_adec_Rural_IIITrim + Tasa_otro_empl_no_pleno_Rural_ITrim + Tasa_otro_empl_no_pleno_Rural_IITrim + Tasa_empl_no_remun_Rural_ITrim + Tasa_empl_no_remun_Rural_IIITrim + Tasa_empl_no_remun_Rural_IVTrim + Tasa_desem_adecuado_Rural_IITrim + Tasa_desem_adecuado_Rural_IIITrim + Tasa_desem_adecuado_Rural_IVTrim, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Tasa_sub_empl_adec_Rural_ITrim, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual"
```

```
(Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Tasa_sub_empl_adec_Rural_IITrim, type= 'o', lwd=2, axes=FALSE, col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_sub_empl_adec_Rural_IITrim, type= 'o', lwd=2, axes=FALSE, col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_otro_empl_no_pleno_Rural_ITrim, type= 'o', lwd=2, axes=FALSE, col="cyan", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_otro_empl_no_pleno_Rural_IITrim, type= 'o', lwd=2, axes=FALSE, col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_empl_no_remun_Rural_ITrim, type= 'o', lwd=2, axes=FALSE, col="orchid", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Tasa_empl_no_remun_Rural_IITrim, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Tasa_empl_no_remun_Rural_IITrim, type= 'o', lwd=2, axes=FALSE, col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_empl_no_remun_Rural_IVTrim, type= 'o', lwd=2, axes=FALSE, col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_desem_adecuado_Rural_IITrim, type= 'o', lwd=2,
```

```
axes=FALSE, col="cyan", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_desem_adecuado_Rural_IIITrim, type= 'o', lwd=2,
      axes=FALSE, col="chartreuse", ann=F)
```

```
par(new=TRUE)
```

```
plot(Tasa_desem_adecuado_Rural_IVTrim, type= 'o', lwd=2,
      axes=FALSE, col="orchid", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ IPA + IPM_Ene + IPM_Feb +
IPM_Jul + IPM_Nov + IPM_Dic, data = Cacao_Nacional)

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(IPA, type= 'b', lwd=2, axes=FALSE, main = "Producción
de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-
2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")

par(new=TRUE)

```

```

plot(IPM_Feb, type= 'o', lwd=2, axes=FALSE, col="blue", an-
n=F)

par(new=TRUE)

plot(IPM_Dic, type= 'o', lwd=2, axes=FALSE, col="orchid",
ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

```

```

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

```

```

modelo <- lm(Produccion ~ IPX_Ene + IPX_Feb + IPX_Mar +
IPX_May + IPX_Jun + IPX_Jul + IPX_Ago + IPX_Sep + IPX_Oct +
IPX_Nov + IPX_Dic + IPI_Ene + IPI_Feb + IPI_Mar +
IPI_Abr + IPI_May + IPI_Jun + IPI_Jul + IPI_Ago + IPI_Sep +
IPI_Oct + IPI_Nov + IPI_Dic, data = Cacao_Nacional)

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(IPX_Ene, type= 'b', lwd=2, axes=FALSE, main = "Pro-
ducción de cacao (Theobroma cacao): CNA (2000) y ESPAC
(2002-2020)", ylab = "Producción anual (Ton)", xlab="Año
productivo", col="red")

par(new=TRUE)

plot(IPX_Feb, type= 'o', lwd=2, axes=FALSE, col="blue", an-

```

```
n=F)
```

```
par(new=TRUE)
```

```
plot(IPX_May, type= 'o', lwd=2, axes=FALSE, col=" yellow",
ann=F)
```

```
par(new=TRUE)
```

```
plot(IPX_Jul, type= 'o', lwd=2, axes=FALSE, col="cyan",
ann=F)
```

```
par(new=TRUE)
```

```
plot(IPI_Dic, type= 'o', lwd=2, axes=FALSE, col="chartreuse",
ann=F)
```

```
par(new=TRUE)
```

```
plot(IPX_Jun, type= 'o', lwd=2, axes=FALSE, col="orchid",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

transformacion.a.normal

w <- transformacion.a.normal\$transformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

modelo <- lm(Produccion ~ Inf_Men_Ene + Inf_Men_Feb +
Inf_Men_Abr + Inf_Men_Jun + Inf_Men_Jul + Inf_Men_Sep,
data = Cacao_Nacional)

summary(modelo)

ANOVA <- aov(modelo)

summary(ANOVA)

plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)

axis(side=1, at=V, labels= Anualidad)

par(new=TRUE)

plot(Inf_Men_Ene, type= 'b', lwd=2, axes=FALSE, main =
"Producción de cacao (Theobroma cacao): CNA (2000) y ES-
PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="A-
ño productivo", col="red")

par(new=TRUE)

plot(Inf_Men_Jun, type= 'o', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Inf_Men_Jul, type= 'o', lwd=2, axes=FALSE, col=" yel-
low", ann=F)

par(new=TRUE)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Aplicacion_Fertilizantes ~ Fosfato_diam_Fert_Ene + Fosfato_diam_Fert_Mar + Fosfato_diam_Fert_Abr, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Aplicacion_Fertilizantes, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Fosfato_diam_Fert_Ene, type= 'b', lwd=2, axes=FALSE,
main = "Aplicación de fertilizantes en cacao (Theobroma
cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Aplicación
anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Fosfato_diam_Fert_Abr, type= 'o', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Aplicacion_Fertilizantes ~ Muriato_K_Fert_Ene  
+ Muriato_K_Fert_Abr, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Aplicación_Fertilizantes, type= 'o', col="black", xax-  
t="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Muriato_K_Fert_Ene, type= 'b', lwd=2, axes=FALSE,  
main = "Aplicación de fertilizantes en cacao (Theobroma  
cacao): CNA (2000) y ESPAC (2002-2020)", ylab= "Aplicación
```

```
anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Muriato_K_Fert_Abr, type= 'o', lwd=2, axes=FALSE,  
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Propiconazol_Fungi_Ene + Propiconazol_Fungi_Feb + Propiconazol_Fungi_Mar + Propiconazol_Fungi_Oct + Propiconazol_Fungi_Nov + Propiconazol_Fungi_Dic, data = Cacao_Nacional)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Propiconazol_Fungi_Mar, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab= "Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Propiconazol_Fungi_Nov, type= 'o', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Propiconazol_Fungi_Ene, type= 'o', lwd=2, axes=FALSE,
col="yellow", ann=F)
```

```
par(new=TRUE)
```

```
plot(Propiconazol_Fungi_Feb, type= 'o', lwd=2, axes=FALSE,
col="cyan", ann=F)
```

```
par(new=TRUE)
```

```
plot(Propiconazol_Fungi_Dic, type= 'o', lwd=2, axes=FALSE,
col="orchid", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

“Provincias productoras de interés (base ESPAC 2002)”

```
getwd()
```

```
library(readxl)
```

```
Cacao_Guayas <- read_excel("G:/Libros para Ingeniería/Regresión lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/Cacao.Guayas.xlsx")
```

```
View(Cacao_Guayas)
```

```
str(Cacao_Guayas)
```

```
names(Cacao_Guayas)
```

```
cor(Cacao_Guayas)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004", "2005", "2006", "2007", "2008", "2009", "2010", "2011", "2012", "2013", "2014", "2015", "2016", "2017", "2018", "2019", "2020")
```

```
V <- c(1:21)
```

```
Produccion <- c(21591, 56645, 19239, 29344, 27035, 26565, 27303, 30052, 36520, 38620, 46088, 49448, 40917, 46159, 31553, 49448, 49233, 51640, 56645, 53305, 55171)
```

```
Superficie_plantada <- c(51227, 62823, 74419, 75622, 75650, 86779, 83441, 97945, 96206, 97486, 97443, 101150, 106732, 108868, 59579, 89282, 101724, 96423, 96969, 100688, 101881)
```

```
Superficie_cosechada <- c(69179, 89331, 70129, 70125, 65715, 72616, 71567, 80447, 78049, 79768, 79508, 70580, 88047, 89158, 52067, 78651, 89607, 84869, 89331, 83434, 84272)
```

```
Ventas <- c(17733, 19716, 18075, 26732, 23793, 26353, 26154, 29834, 34003, 38608, 45425, 49307, 40739, 46036, 31515, 49447, 47505, 51636, 51718, 52813, 53908)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Superficie_
```

```
cosechada + Ventas, data = Cacao_Guayas)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-  
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE, main  
= "Producción de cacao (Theobroma cacao): CNA (2000) y ES-  
PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="A-  
ño productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Superficie_cosechada, type= 'b', lwd=2, axes=FALSE,  
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="yellow",  
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```

lillie.test(rstandard(modelo))
pearson.test(rstandard(modelo))
sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal
w <- transformacion.a.normal$tranformed
jarque.test(w)
ad.test(w)

lillie.test(w)
pearson.test(w)

sf.test(w)

getwd()
library(readxl)

```

Cacao_LosRios <- read_excel("G:/Libros para Ingeniería/Regresión lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/Cacao.LosRios.xlsx")

View(Cacao_LosRios)

str(Cacao_LosRios)

names(Cacao_LosRios)

cor(Cacao_LosRios)

También, se pueden ingresar variables de interés así:

Anualidad <- c("2000", "2001", "2002", "2003", "2004", "2005", "2006", "2007", "2008", "2009", "2010", "2011", "2012", "2013", "2014", "2015", "2016", "2017", "2018", "2019", "2020")

V <- c(1:21)

Produccion <- c(8940, 10887, 14434, 20973, 19465, 22255, 17078, 13849, 14225, 28410, 32829, 39040, 30109, 22113, 34076, 36185, 41187, 52815, 58599, 43993, 45940)

Superficie_plantada <- c(58572, 78999, 99425, 97116, 95326,

```
96781, 93873, 92443, 96293, 100014, 102531, 115277, 107849,
105462, 97270, 106116, 125186, 131686, 133219, 118785,
120534)
```

```
Superficie_cosechada <- c(84311, 84456, 96669, 92301,
89740, 85134, 80971, 79767, 76928, 84222, 73598, 85363,
82679, 73614, 80050, 88199, 96200, 105503, 116427, 86912,
87056)
```

```
Ventas <- c(8115, 10113, 13735, 20350, 18866, 21797, 16709,
13297, 12841, 28369, 32575, 38926, 29970, 22052, 33882,
36137, 41124, 52812, 57830, 46065, 48062)
```

```
Precipit_Ene <- c(110.60, 514.20, 157.80, 206.40, 129.95,
53.50, 425.00, 200.10, 563.60, 391.80, 333.50, 350.20, 731.00,
278.90, 230.00, 223.10, 216.20, 209.30, 368.25, 527.21, 558.70)
```

```
Precipit_Feb <- c(283.30, 320.80, 647.00, 282.80, 199.55,
116.30, 524.70, 123.00, 444.90, 238.70, 737.30, 657.50, 577.70,
464.65, 497.12, 529.59, 562.06, 591.55, 621.04, 694.44, 767.83)
```

```
Precipit_Mar <- c(412.20, 404.50, 848.60, 236.20, 310.90,
385.60, 258.50, 379.20, 371.10, 180.70, 582.10, 613.95, 645.80,
454.40, 446.01, 437.62, 429.23, 431.43, 433.63, 454.80, 475.98)
```

```
Precipit_Abr <- c(186.40, 312.50, 435.20, 113.90, 264.30,
414.70, 54.10, 246.00, 329.80, 145.90, 403.00, 573.70, 499.10,
250.40, 238.30, 228.82, 219.34, 209.86, 325.57, 441.28, 464.72)
```

```
Precipit_May <- c(41.50, 40.90, 109.80, 27.30, 13.65, 0.00,
20.60, 32.30, 93.20, 103.55, 112.00, 26.50, 429.90, 61.45,
64.08, 66.71, 69.34, 173.88, 278.41, 317.56, 356.70)
```

```
Precipit_Jun <- c(9.80, 0.00, 2.80, 11.80, 3.70, 0.00, 10.60,
4.80, 1.70, 14.35, 20.30, 71.40, 64.30, 45.91, 50.10, 54.28,
58.47, 62.66, 66.85, 71.04, 75.23)
```

```
Precipit_Jul <- c(0.00, 3.10, 1.60, 4.70, 2.20, 0.00, 0.00, 3.40,
0.00, 0.95, 48.90, 63.60, 3.20, 29.31, 32.05, 34.79, 37.53, 40.27,
43.00, 45.74, 48.48)
```

```
Precipit_Nov <- c(0.00, 0.00, 1.80, 139.70, 69.85, 0.00, 5.00,
7.60, 4.65, 0.55, 17.50, 7.80, 24.30, 0.00, 140.60, 182.69,
224.78, 266.87, 140.14, 13.42, 14.60)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Superficie_
cosechada + Ventas, data = Cacao_LosRios)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ES-PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Superficie_cosechada, type= 'o', lwd=2, axes=FALSE, col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="orchid", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$transformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Precipit_Ene + Precipit_Feb +
Precipit_Mar + Precipit_Abr + Precipit_May + Precipit_Jun +
Precipit_Jul + Precipit_Ago + Precipit_Sep + Precipit_Oct +
Precipit_Nov + Precipit_Dic, data = Cacao_LosRios)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Feb, type= 'b', lwd=2, axes=FALSE, main =
"Producción de cacao (Theobroma cacao): CNA (2000) y ES-
PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="A-
ño productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Precipit_Mar, type= 'o', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Abr, type= 'o', lwd=2, axes=FALSE, col="yel-
low", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_May, type= 'o', lwd=2, axes=FALSE, col="cy-
an", ann=F)
```

```
par(new=TRUE)
```

```
plot(Precipit_Jun, type= 'o', lwd=2, axes=FALSE, col="char-
treuse", ann=F)
```

```

par(new=TRUE)

plot(Precipit_Nov, type= 'o', lwd=2, axes=FALSE, col="or-
chid", ann=F)

grid(col="black", lwd=0.05)

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

```

```

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

getwd()

```

```
library(readxl)

Cacao_Manabi <- read_excel("G:/Libros para Ingeniería/Regresión lineal para ingeniería. Excel, R, SAS, Wolfram System Modeler y Python.Jupyter/Ejercicios/PIS/Cultivos ESPAC 2000 a 2019/Cacao.Manabi.xlsx")

View(Cacao_Manabi)

str(Cacao_Manabi)

names(Cacao_Manabi)

cor(Cacao_Manabi)
```

También, se pueden ingresar variables de interés así:

```
Anualidad <- c("2000", "2001", "2002", "2003", "2004",
"2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "2018",
"2019", "2020")

V <- c(1:21)
```

```
Produccion <- c(9760, 10683, 11294, 13357, 18841, 18155,
16506, 15099, 11780, 16396, 15413, 24830, 10650, 10294,
30152, 28237, 22309, 33117, 33487, 26371, 27294)
```

```
Superficie_plantada <- c(52577, 70286, 87995, 88734, 88713,
92741, 91999, 97006, 105595, 103699, 102346, 98658, 97382,
97799, 95604, 104849, 125839, 124874, 126972, 52578, 52578)

Superficie_cosechada <- c(82593, 82807, 84127, 84830, 84734,
85475, 82735, 86546, 93823, 92839, 77976, 77165, 64374,
75746, 81070, 85396, 94904, 102207, 114553, 86436, 86650)

Ventas <- c(8455, 9467, 9066, 12810, 17671, 17750, 16348,
13687, 11459, 16328, 15269, 24481, 10452, 10222, 30056,
28066, 22295, 33107, 26666, 20225, 22411)

Precipit_Ene <- c(61.03, 373.60, 103.85, 239.26, 93.33, 123.13,
158.53, 155.15, 145.54, 149.75, 139.70, 98.13, 233.10, 187.47,
94.10, 43.05, 180.30, 96.30, 22.90, 72.40, 53.78)

Precipit_Feb <- c(125.15, 220.30, 356.30, 318.03, 240.30,
186.98, 330.70, 154.40, 264.45, 149.60, 207.87, 118.70, 403.50,
194.03, 215.45, 142.95, 127.10, 296.10, 187.30, 177.30, 186.86)

Precipit_Mar <- c(125.80, 402.00, 244.25, 109.45, 189.83,
192.93, 348.55, 292.75, 229.63, 90.30, 176.07, 55.95, 286.97,
256.20, 105.70, 145.70, 269.30, 169.50, 48.10, 177.40, 150.72)

Temp_Ene <- c(25.80, 25.75, 26.50, 26.30, 26.55, 27.00, 26.25,
26.95, 24.70, 26.00, 26.55, 25.50, 26.03, 25.30, 27.26, 27.34,
28.10, 27.10, 27.20, 27.10, 27.77)
```

```
Temp_Jun <- c(24.20, 23.60, 24.85, 24.80, 24.45, 24.30, 24.95,
25.05, 24.85, 25.85, 24.90, 25.75, 25.65, 24.20, 26.90, 27.50,
26.80, 25.10, 25.80, 26.49, 26.62)
```

```
Temp_Ago <- c(24.15, 23.95, 23.80, 25.00, 24.80, 24.60, 25.55,
23.80, 24.90, 26.05, 24.60, 24.75, 24.10, 23.90, 26.35, 27.05,
26.00, 25.80, 26.40, 26.17, 26.28)
```

```
modelo <- lm(Produccion ~ Superficie_plantada + Superficie_
cosechada + Ventas, data = Cacao_Manabi)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Superficie_plantada, type= 'b', lwd=2, axes=FALSE, main
= "Producción de cacao (Theobroma cacao): CNA (2000) y ES-
PAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="A-
```

```
ño productivo", col="red")
```

```
par(new=TRUE)
```

```
plot(Superficie_cosechada, type= 'o', lwd=2, axes=FALSE,
col="blue", ann=F)
```

```
par(new=TRUE)
```

```
plot(Ventas, type= 'o', lwd=2, axes=FALSE, col="orchid",
ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

```
modelo <- lm(Produccion ~ Precipit_Ene + Precipit_Feb + Precipit_Mar, data = Cacao_Manabi)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, ann=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Precipit_Ene, type= 'b', lwd=2, axes=FALSE, main = "Producción de cacao (Theobroma cacao): CNA (2000) y ESPAC (2002-2020)", ylab = "Producción anual (Ton)", xlab="Año productivo", col="red")
```

```
par(new=TRUE)
```

```

plot(Precipit_Feb, type= 'o', lwd=2, axes=FALSE, col="blue",
ann=F)

par(new=TRUE)

plot(Precipit_Mar, type= 'o', lwd=2, axes=FALSE, col="chartreuse",
ann=F)

grid(col="black", lwd=0.05)

```

modelo

plot(modelo)

summary(modelo)

coef(modelo)

shapiro.test(rstandard(modelo))

qqnorm(rstandard(modelo))

qqline(rstandard(modelo))

ncvTest(model = modelo)

jarque.test(rstandard(modelo))

ad.test(rstandard(modelo))

cvm.test(rstandard(modelo))

lillie.test(rstandard(modelo))

pearson.test(rstandard(modelo))

sf.test(rstandard(modelo))

transformacion.a.normal <- RE.Jhonson(rstandard(modelo))

transformacion.a.normal

w <- transformacion.a.normal\$tranformed

jarque.test(w)

ad.test(w)

lillie.test(w)

pearson.test(w)

sf.test(w)

```
modelo <- lm(Produccion ~ Temp_Ene + Temp_Jun + Temp_
Ago, data = Cacao_Manabi)
```

```
summary(modelo)
```

```
ANOVA <- aov(modelo)
```

```
summary(ANOVA)
```

```
plot(Produccion, type= 'o', col="black", xaxt="n", lwd=2, an-
n=F)
```

```
axis(side=1, at=V, labels= Anualidad)
```

```
par(new=TRUE)
```

```
plot(Temp_Ene, type= 'b', lwd=2, axes=FALSE, main="Pro-
ducción de arroz (Oryza sativa): CNA (2000) y ESPAC (2002-
2020)", ylab="Producción anual (Ton)", xlab="Año producti-
vo", col="red")
```

```
par(new=TRUE)
```

```
plot(Temp_Jun, type= 'b', lwd=2, axes=FALSE, col="blue",
ann=F)
```

```
par(new=TRUE)
```

```
plot(Temp_Ago, type= 'b', lwd=2, axes=FALSE, col="magen-
ta", ann=F)
```

```
grid(col="black", lwd=0.05)
```

```
modelo
```

```
plot(modelo)
```

```
summary(modelo)
```

```
coef(modelo)
```

```
shapiro.test(rstandard(modelo))
```

```
qqnorm(rstandard(modelo))
```

```
qqline(rstandard(modelo))
```

```
ncvTest(model = modelo)
```

```
jarque.test(rstandard(modelo))
```

```
ad.test(rstandard(modelo))
```

```
cvm.test(rstandard(modelo))
```

```
lillie.test(rstandard(modelo))
```

```
pearson.test(rstandard(modelo))
```

```
sf.test(rstandard(modelo))
```

```
transformacion.a.normal <- RE.Jhonson(rstandard(modelo))
```

```
transformacion.a.normal
```

```
w <- transformacion.a.normal$tranformed
```

```
jarque.test(w)
```

```
ad.test(w)
```

```
lillie.test(w)
```

```
pearson.test(w)
```

```
sf.test(w)
```

REFERENCIAS BIBLIOGRÁFICAS

Águila, L. M. (2012). Caracterización morfológica y sensorial del cacao nacional (*Theobroma cacao L*) a nivel de fincas en Cantón Las Naves, Provincia Bolívar. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Aguirre, Q. V. (2015). *Identificación de cadenas de comercialización de arroz (*Oriza sativa L*) en pequeños productores de “Cooperativa Alianza Definitiva” de Cuenca Central de Río Daule, Provincia del Guayas*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Álava, V. L. (2013). *Respuesta del cultivo de banano (*Musa sapientum*) a aplicación de dos tipos de fertilizantes foliares orgánicos en diferentes fases lunares en Cantón Pueblo viejo, Provincia Los Ríos*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Alvarado, C. D. (2018). *Evaluación de incidencia de problemas fitosanitarios en híbrido de café robusta (*Coffea canephora Pierre*) con cinco densidades de siembra en Cantón Caluma, Provincia Bolívar*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Anchapaxi, C. R. (2013). *Evaluación agronómica del cultivo de*

*maíz suave en choclo (*Zea mays amylacea*) variedad Mishca con utilización de tres abonos orgánicos en tres dosis en zona de Pifo, Provincia de Pichincha.* Guaranda, Provincia Bolívar, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Arévalo, T. J. (2012). *Evaluación de sistemas de cultivo, prácticas de labranza y rotación de cultivo de maíz duro (*Zea Mays L*) en microcuenca del Río Alumbre, Cantón Chillanes, Provincia Bolívar, Ecuador.* Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Calero, C. F. (2019). *Evaluación morfológica y agronómica de cacao (*Theobroma cacao L*) nacional fino de aroma con implementación de diferentes prácticas agrícolas en fertilización y poda.* Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Capa, S. H. (2015). *Probabilidades y estadística: Para una gestión científica de la información.* Ladrón de Guevara E11-253, Quito, Ecuador: Unidad de Publicaciones de la Facultad de Ciencias y Vicerrectorado de Docencia de la Escuela Politécnica Nacional.

Carhuaricra, R. J. (2013). *Caracterización morfo agronómica de*

*10 accesiones de cebada de grano desnudo (*Hordeum vulgare L*) en Granja Laguacoto II, Cantón Guaranda, Provincia Bolívar.* Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Chávez, V. M. (2018). *Validación agronómica de 20 cultivares de fréjol arbustivo (*Phaseolus vulgaris L*) en Localidad de Monte Carlos, Cantón Urdaneta, Provincia Los Ríos.* Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Chicaiza, P. J., & Curichumbi, P. D. (2012). *Estudio de línea base de producción de papa (*Solanum tuberosum L*) en cinco comunidades de Parroquia La Matriz, Cantón Guamote, Provincia Chimborazo.* Guaranda, Provincia Bolívar, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Córdova, T. J., & Solís, A. M. (2019). *Evaluación agronómica de respuesta de cuatro líneas promisorias de trigo duro (*Triticum durum*) a fertilización nitrogenada en dos localidades de Provincia Bolívar.* Guaranda, Provincia de Bolívar, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad

Estatal de Bolívar.

Curipallo, S. D. (2013). *Evaluación de cuatro dosis de ácido giberélico en estado fisiológico de floración de tomate de árbol (*Cyphornandra betacea*) en Patate, Provincia Tungurahua*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Gonzaga, O. D. (2013). *Recuperación de palma aceitera (*Elaeis guineensis Jacq*) bajo estrés por desbalance catiónico de Ca, Mg y K con uso de diferentes fuentes de Mg y K, La Concordia*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

González, B. G. (1985). *Métodos Estadísticos y Principios de Diseño Experimental*. Quito, Ecuador: Editorial Universitaria. Universidad Central del Ecuador.

González, C. L. (2015). *Identificación de sistemas de producción de maíz suave (*Zea mays L*) en micro cuenca del Río San Pablo, Cantón San Miguel, Provincia Bolívar*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Gualotuña, L. E. (2012). *Evaluación agronómica de eficiencia de uso de nitrógeno en cultivo de cebada (*Hordeum vulgare L*) variedad INIAP-Guaranga 2010 con cinco niveles de fertilización nitrogenada en Granja Laguacoto II, Cantón Guaranda*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

vulgare L) variedad INIAP-Guaranga 2010 con cinco niveles de fertilización nitrogenada en Granja Laguacoto II, Cantón Guaranda. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Gujarati, D. N., & Porter, D. C. (2010). *Econometría*. Colonia Desarrollo Santa Fe. Delegación Álvaro Obregón. México, D. F.: McGraw-Hill/Interamericana Editores, S.A. DE C.V.

Juela, M. L., & Mosquera, C. P. (2019). *Evaluación agromorfológica de plántulas de cinco variedades de naranja mediante multiplicación in vitro de embriones inmaduros con tres dosis de ácido giberélico*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Ledesma, J. M. (2017). *Valoración de canales de comercialización del rubro naranja (*Citrus sinensis L*) en Cantón Caluma, Provincia Bolívar*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

Levine, D. M., Krehbiel, T. C., & Berenson, M. L. (2006). *Estadística para Administración*. Col. Industrial Atoto.

- Naucalpan de Juárez, estado de México: Pearson Educación de México, S. A. de C. V.
- Moya, C.E. (2018). *Valoración de producción y comercialización de maíz duro (*Zea Mays L*) en Cantón Pueblo Viejo, Provincia Bolívar*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Ramírez, M. P. (2001). *Principios de Econometría*. Universidad Autónoma Chapingo: Centro de Investigaciones Económicas Sociales y Tecnológicas de la Agroindustria y la Agricultura Mundial (CIESTAAM). Universidad Autónoma Chapingo (UACH).
- Remache, P. J. (2012). *Caracterización morfo agronómica de 24 accesiones de trigo duro (*Triticum turgidum L, Thell durum*) en Localidad Laguacoto II, Cantón Guaranda, Provincia Bolívar*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Rumiguano, Q. M. (2019). *Respuesta agronómica del maíz (*Zea mays L*) INIAP-III a fertilización nitrogenada y tres tipos de labranza en Chalongoto, Cantón Guaranda, Provincia Bolívar*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Suárez, C. L. (2013). *Evaluación de producción de cebada (*Hordeum vulgare L*) con prácticas agroforestales de conservación del suelo en microcuenca del Río Illangama, Cantón Guaranda, Provincia Bolívar, Ecuador*. Guaranda, Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Ulloa, V. E. (2012). *Caracterización de producción de naranja (*Citrus sinensis L*) en Parroquia Las Mercedes, Cantón Las Naves, Provincia Bolívar*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Urrutia, Q. S. (2013). *Evaluación del efecto de protectores sobre la producción y calidad del banano en Recinto Pailón, Chacarita, Cantón Ventanas, Provincia Los Ríos*. Guaranda, Ecuador: Escuela de Agronomía. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Váldez, R. J. (2015). *Evaluación morfo agronómica y productiva de ocho variedades de arroz (*Oriza sativa L*) en Recinto Los Cerritos, Cantón Urdaneta, Provincia Los Ríos*. Guaranda, Ecuador: Escuela de Agronomía. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.

- Vela, V. J. (2013). *Validación de seis formulaciones de fertilizantes químicos en cultivo de papa variedad súper chola (*Solanum tuberosum L.*) en Comunidad de Guitig Alto, Cantón Mejía, Provincia Pichincha*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.
- Wackerly, D. D., Mendenhall, W. I., & Scheaffer, R. L. (2010). *Estadística matemática con aplicaciones*. Col. Cruz Manca, Santa Fe. México, D. F.: Cengage Learning Editores, S. A. de C. V., una Compañía de Cengage Learning, Inc.
- Yépez, E. A., & Erazo, B. A. (2015). *Estudio de línea base con canales de comercialización del rubro para (*Solanum tuberosum L.*) en dos sectores de Parroquia Guanujo, Cantón Guaranda, Provincia Bolívar*. Guaranda, Provincia Bolívar. Ecuador: Escuela de Ingeniería Agronómica. Facultad de Ciencias Agropecuarias, Recursos Naturales y del Ambiente. Universidad Estatal de Bolívar.



Moisés Arreguín Sámano

Profesor investigador de la Universidad Estatal de Bolívar (UEB).



Andrea Damaris Hernández Allauca

Magíster en Ciencias de la Educación – Aprendizaje de la Matemática, Licenciada en Ciencias de la Educación- Profesora en Ciencias Exactas. Actualmente docente investigadora de la Escuela Politécnica de Chimborazo en el Grupo de Investigación y Transferencia de Tecnologías en Recursos Hídricos (GITRH) y Grupo de Investigación en Turismo (GITUR).



Salvador Sampayo Maldonado

Profesor de la carrera de Biología en la Facultad de Estudios Superiores Iztacala. De la Universidad Nacional Autónoma de México. Tlalnepantla, estado de México.



Mario Alejandro Paguay Alvarado

Ingeniera Civil, Maestría en Ingeniería Civil con mención en Gestión de la Construcción (c). Investigadora independiente.

