



UNIVERSIDAD DE JAÉN

Material del curso “Análisis de datos procedentes de investigaciones mediante programas informáticos”

Manuel Miguel Ramos Álvarez

MATERIAL IV “EXPLICACIÓN CON REGRESIÓN”

Índice

4.	Acercamiento con el fin explicativo: análisis inferencial orientado a Regresión.	2
4.1.	Análisis de Regresión para investigaciones correlacionales/covariacionales.	3
4.1.1.	Introducción a regresión	3
4.1.2.	Análisis global de la regresión lineal.	5
4.1.3.	Resumen del Modelo.	6
4.2.	El análisis de múltiples variables predictoras cuantitativas o perspectiva de Regresión Múltiple	7
4.2.1.	Resumen del Modelo.	8
4.2.2.	La especificación de la interacción en el Modelo	9
4.2.3.	Análisis detallado mediante regresión. Las tendencias curvilíneas	10
4.2.4.	El caso general: análisis de regresión de modelos complejos	11
4.3.	Alternativas robustas y No paramétricas de regresión	12
4.4.	Opciones de Regresión Lineal en los paquetes de Análisis	13
4.4.1.	Opciones de Regresión Lineal en SPSS 12.0/15.0.	14
4.4.2.	Opciones de Regresión Lineal en Statistica.	15
4.5.	Realización de los supuestos de prácticas.	17
4.5.1.	Ejemplificación del análisis de Regresión mediante el Supuesto 1	18

4. Acercamiento con el fin explicativo: análisis inferencial orientado a Regresión.


- 2 Aproximaciones:
 - Basada en el contraste de Hipótesis Estadísticas.
 - Basada en la potencia estadística y en los intervalos confidenciales.
- Tener presente el repaso sobre el contraste de Hipótesis y en general el módulo inicial sobre Modelización.

4.1. Análisis de Regresión para investigaciones correlacionales/covariacionales

4.1.1. Introducción a regresión

Interpretación básica a partir del Diagrama de dispersión

Figura adaptada a partir de Ramos, M.M.; Catena, A. y Trujillo, H. (2004). *Manual de Métodos y Técnicas de Investigación en Ciencias Del Comportamiento*. Madrid: Biblioteca Nueva.



Bases de la estimación lineal

- Todas las predicciones del modelo, \hat{Y}_i , descansan sobre la línea recta.
- Los errores de predicción ó residuales, $e_i = Y_i - \hat{Y}_i$, se definen como la distancia vertical entre los puntos de datos y la recta.
- El parámetro de intersección B0 corresponde al valor de \hat{Y}_i cuando X_i es cero ó punto de origen de la recta.
- La pendiente B1 cuantifica el cambio en \hat{Y}_i por cada incremento unitario en X_i .
- Positiva, lo que expresa un crecimiento en el criterio conforme aumenta el predictor
- negativa, expresando decrementos en el criterio correspondiendo a incrementos en el predictor.

- A partir de la Suma de Cuadrados Error, y teniendo en cuenta el modelo ampliado ó completo en comparación al restringido, podemos reconstruir el proceso de contrastación de Hipótesis tal y como vimos en el Modelo General.
- Proceso de análisis general.
- Se ajustan los modelos correspondientes a los datos con objeto de estimar los parámetros correspondientes
- Se estima la medida de Reducción Proporcional del Error (RPE) del modelo Ampliado en referencia a un modelo Compacto
- Entonces, La medida RPE y su complementaria, 1-RPE, se transforman en Medias Cuadráticas dividiendo por los grados de libertad correspondientes.
- El cociente entre ambas MMCC nos lleva a un estadístico F que nos proporciona información sobre lo que ganamos con el modelo Ampliado por parámetro añadido.
- Finalmente comparamos el valor de F con un valor crítico obtenido a partir del modelo de distribución F según el nivel de significación que imponemos. Si el valor de F asociado a la magnitud RPE supera el valor crítico, entonces nos inclinamos en contra de la Hipótesis Nula, o lo que es equivalente, a favor del modelo Ampliado frente al modelo Compacto y al contrario si el valor es inferior.

4.1.2. Análisis global de la regresión lineal

Tabla Resumen de la perspectiva de Modelización en el contexto de Regresión.

Cuadro 8.1 Adaptado a partir de de Ramos, M.M.; Catena, A. y Trujillo, H. (2004). *Manual de Métodos y Técnicas de Investigación en Ciencias Del Comportamiento*. Madrid: Biblioteca Nueva.

Fuente	SC	gl (v)	MC	F _k	η ²	p
Regres.	SCR= SCe(COM)- SCe(SAT)	1	$MCR = \frac{SCR}{1}$	$\frac{MCR}{MC\varepsilon} *$	$\frac{SCR}{SCE(COM)}$	$p(F_k)$
Err. o Residual	SCe(SAT)	N-2	$MC\varepsilon = \frac{SC(SAT)}{N-2}$			
Total	SCe(COM)	N-1				

*p≤α

Supuesto 1
 Analizar → Regresión → lineal
 → Dependiente: FreqY;
 Independientes: X1;
 Estadísticos → Estimaciones →
 Continuar → Aceptar

Statistics → Multiple Regression
 → Variables: Dependent: FreqY;
 Independent: X1 → OK →
 Aceptar → *Pestaña* Advanced →
 Summary → ANOVA →
Pestaña Residuals

Interpretación:

Análisis de los parámetros

- Si deseamos probar la significación del parámetro B₀ entonces, según la perspectiva de modelización tendríamos que comparar los modelos:

$$\left\{ \begin{array}{l} AMP : Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \\ COM1 : Y_i = \beta_1 X_i + \varepsilon_i \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : \beta_0 = 0 \\ H_1 : \beta_0 \neq 0 \end{array} \right\}$$

- Para probar la significación del parámetro B₁ entonces compararíamos los modelos:

$$\left\{ \begin{array}{l} AMP : Y_i = \beta_0 + \beta_1 \cdot X_i + \varepsilon_i \\ COM2 : Y_i = \beta_0 + \varepsilon_i \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : \beta_1 = 0 \\ H_1 : \beta_1 \neq 0 \end{array} \right\}$$

4.1.3. Resumen del Modelo

Los Intervalos Cofidenciales:

- Intersección. $\beta_0 \pm \sqrt{\alpha F_{1;n-2}} \sqrt{\frac{MC_\epsilon}{SC_X}} \sqrt{\frac{\sum X^2}{n}}$ en escala directa ó $\beta_0 \pm \sqrt{\alpha F_{1;n-2}} \sqrt{\frac{MC_\epsilon}{n}}$ en escala diferencial respecto a la media del predictor.
- Pendiente. $\beta_1 \pm \sqrt{\alpha F_{1;n-2}} \sqrt{\frac{MC_\epsilon}{SC_X}}$

Donde $SC_X = \sum (X - \bar{X})^2$

- Para estimar la **potencia estadística** nos basaremos en RPE como medida del efecto de tratamiento, o mejor la medida ajustada, y a partir del mismo buscaremos en las curvas de potencia o mediante un programa especializado.

Mejorar la interpretación de las predicciones

- En ocasiones interesa cambiar la escala de la ecuación de regresión, básicamente refiriendo todos los puntos con respecto al promedio de las variables.
 $\hat{Y} = \beta_0^* + \beta_1(X_i - \bar{X})$.
- Donde $\beta_0^* = \bar{Y}$. En otras palabras, el parámetro de origen recoge ahora la coordenada (\bar{X}, \bar{Y}) .

INTERVALOS CONFIDENCIALES
 > Supuesto 1
 Analizar → Regresión → lineal →
 Dependiente: FreqY; Independientes: X1;
 Estadísticos → Estimaciones, Intervalos
 de confianza → Continuar → Aceptar

 Statistics → Advanced
 Linear/NonLinear → General Linear
 Models → General Linear Models → OK →
 Variables: Dependent: FreqY; Continuous
 pred: X1 → OK → Aceptar → *Pestaña*
 Summary → Coefficients

POTENCIA
 > Supuesto 1
 Statistics → Power Analysis → Power Calculation → One Correlation,
 t-Test → OK → Rho: 0,44 (es R_{Adj}^2); N: 18 Alpha: 0,05 → OK →
 Calculate Power → start N: 10; End N: 100 → Power vs. N; Power
 vs. Rho; Power vs. Alpha

 Opciones del programa Statistica:
 • Power Calculation. Cálculo de la potencia y Funciones de Potencia para
 estimar la potencia a partir del tamaño del efecto, alfa y tamaño
 muestral.
 • Sample Size Calculation. Cálculo del tamaño muestral a requerido para
 lograr un determinado nivel de potencia y también en funcion del resto
 de parámetros.
 • Interval Estimation. Estimación por Intervalos a partir de variantes
 analíticas especializadas que no suelen aparecer en los programas de
 análisis convencionales.
 • Probability Distributions. Modelos No centralizados que están
 implicados en las estimaciones de Potencia y del tamaño muestral.

Interpretación:

Interpretación:

4.2. El análisis de múltiples variables predictoras cuantitativas o perspectiva de Regresión Múltiple

- Evaluar la significación de cada uno de los predictores a través de su pendiente asociada y se corresponde con la vertiente condicional de modelización.

$$\left\{ \begin{array}{l} AMP: Y_i = \beta_0 + \beta_1 X1_i + \beta_2 X2_i + \dots + \beta_{p-1} XP-1_i + \beta_p XP_i + \varepsilon_i \\ COM1: Y_i = \beta_0 + \beta_1 X1_i + \beta_2 X2_i + \dots + \beta_{p-1} XP-1_i + \varepsilon_i \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0: \beta_p = 0 \\ H_1: \beta_p \neq 0 \end{array} \right\}$$

- la correlación que interviene en la estimación del parámetro es básicamente una **correlación semiparcial** en la que se controla el influjo del resto de predictores secundarios. En definitiva, para un modelo de regresión múltiple con por ejemplo dos predictores,

Extensión de la Tabla Resumen de la perspectiva de Modelización a Regresión Múltiple

Cuadro 8.6 Adaptado a partir de Ramos, M.M.; Catena, A. y Trujillo, H. (2004). *Manual de Métodos y Técnicas de Investigación en Ciencias Del Comportamiento*. Madrid: Biblioteca Nueva.

Fuente	SC	gl (v)	MC	F _k	η ²	p
Regres	SCR= SCe(COM)- SCe(SAT)	p	$MC = \frac{SC}{gl}$	$\frac{MCR}{MC\varepsilon}^*$	$\frac{SCR}{SCE(COM)}$	$p(F_k)$
X1	SCR1= SCe(COM1)- SCe(SAT)	1		$\frac{MCR1}{MC\varepsilon}^*$	$\frac{SCR1}{SCE(COM1)}$	$p(F_k)$
...
Xp	SCRp= SCe(COMp)- SCe(SAT)	1		$\frac{MCRp}{MC\varepsilon}^*$	$\frac{SCRp}{SCE(COMp)}$	$p(F_k)$
Err. ó Residual	SCe(SAT)	N-(p+1)				
Total	SCe(COM)	N-1				

*p ≤ α

- RPE equivale directamente al coeficiente R²

Supuesto 1
 Analizar → Regresión → lineal →
 Dependiente: Y; Independientes: X1,
 X2, X3, X4; Estadísticos →
 Estimaciones → Continuar → Aceptar

 Statistics → Multiple Regression
 → Variables: Dependent: FreqY;
 Independent: X1-X4 → OK →
 Aceptar → Pestaña Advanced →
 Summary → ANOVA → Pestaña
 Residuals.

Interpretación: (evitar comparaciones entre variables a partir de los parámetros B, mejor a partir de RPE).

4.2.1. Resumen del Modelo

- La correlación global ó **múltiple** ahora expresa un índice general de relación entre el conjunto de predictores y el criterio, que por ejemplo para dos predictores se puede calcular mediante la fórmula:

$$R_{Y \cdot 12} = \sqrt{\frac{r_{Y1}^2 + r_{Y2}^2 - 2 \cdot r_{Y1} \cdot r_{Y2} \cdot r_{12}}{1 - r_{12}^2}}$$

- Nuevamente la regresión general llevará asociado un **Error Típico** de Estimación, pero basado ahora en la correlación múltiple:

$$S_{Y \cdot X} = S_Y \cdot \sqrt{1 - R^2}$$

- La Correlación **parcial** que controla el influjo de una variable relevante sobre el predictor focal y sobre el criterio de manera simultánea:
- Similar al anterior, la Correlación **Semiparcial** controla el influjo de una variable relevante sobre el predictor objetivo de manera selectiva.

Estimación de intervalos confidenciales, también son válidas las fórmulas de regresión simple pero incluyendo una medida de redundancia. En general, para la pendiente de cada predictor p, la ecuación es la siguiente:

$$\beta_p \pm \sqrt{\alpha F_{1;n-2}} \sqrt{MC_\epsilon} \sqrt{\frac{1}{SC_{Xp}}} \sqrt{\frac{1}{(1 - R_{p.1...p-1}^2)}}$$

- La correlación $R_{p.1...p-1}^2$ que abreviaremos en adelante como R_p^2 y es la medida RPE obtenida cuando se emplea a todos los predictores p-1 restantes en la predicción del predictor focal p, a modo de asociación entre predictores. Una medida de **redundancia**
- A veces se expresa, su complementaria: medida de **tolerancia**, lo que es único para Xp en la predicción.
- Incluso la inversa de la tolerancia, exactamente lo que entra en el intervalo, recibe un nombre: el factor de **inflación** de la varianza (*VIF: Variance Inflation Factor*).

Respecto a la **estimación de la potencia**, bastaría intercambiar las estimaciones del efecto de tratamiento propias de regresión múltiple con las que aparecían dentro del planteamiento de regresión simple

Analizar ... Estadísticos →
 Estimaciones, Intervalos de
 confianza, Correlaciones parcial y
 semiparcial, Diagnósticos
 Colinealidad ...

 Statistics ... Pestaña
 Advanced → Partial Correlations &
 Redundancy & Current sweep
 matrix.

Para los Intervalos Confidenciales
 y la Potencia seguir las
 indicaciones de Regresión Simple

Interpretación:

4.2.2. La especificación de la interacción en el Modelo

Supongamos una investigación con dos predictores (X1 y X2) de un criterio.

- Para evaluar el efecto principal/aditivo de la variable X1 de manera independiente:

$$\left\{ \begin{array}{l} SAT : Y_i = \beta_0 + \beta_1 \cdot X1_i + \beta_2 \cdot X2_i + \beta_3 \cdot X1 \cdot X2_i + \varepsilon_i \\ COM : Y_i = \beta_0 + \beta_2 \cdot X2_i + \beta_3 \cdot X1 \cdot X2_i + \varepsilon_i \end{array} \right\}$$

- Para el efecto principal de la segunda variable predictora, X2:

$$\left\{ \begin{array}{l} SAT : Y_i = \beta_0 + \beta_1 \cdot X1_i + \beta_2 \cdot X2_i + \beta_3 \cdot X1 \cdot X2_i + \varepsilon_i \\ COM : Y_i = \beta_0 + \beta_1 \cdot X1_i + \beta_3 \cdot X1 \cdot X2_i + \varepsilon_i \end{array} \right\}$$

- Y finalmente, para evaluar la interacción o efecto conjunto de los dos predictores:

$$\left\{ \begin{array}{l} SAT : Y_i = \beta_0 + \beta_1 \cdot X1_i + \beta_2 \cdot X2_i + \beta_3 \cdot X1 \cdot X2_i + \varepsilon_i \\ COM : Y_i = \beta_0 + \beta_1 \cdot X1_i + \beta_2 \cdot X2_i + \varepsilon_i \end{array} \right\}$$

- **Como consecuencia, volveríamos a replantear el análisis de regresión de manera que el modelo final incluyera exclusivamente los parámetros que son significativos.**

- Primero Creamos nosotros la interacción: Transformar → Calcular → Interacc = X1 * X2; Aceptar.
- Entonces Análisis regresión: Analizar → Regresión lineal → Dependiente: FreqY; Independientes: X1, X2, Interacc_i; Estadísticos → Estimaciones → Continuar → Aceptar
- Analizar ... Estadísticos → Estimaciones, Intervalos de confianza, Correlaciones parcial y semiparcial, Diagnósticos Colinealidad ...
- Statistics → Advanced
Linear/NonLinear → General Linear
Models → Factorial Regression → OK → Variables: Dependent: FreqY; Predictor: X1, X2 → OK → Aceptar → Pestaña Summary → Coefficients → Pestaña Advanced → Summary → ANOVA → Pestaña Residuals → Pestaña Advanced → Partial Correlations & Redundancy & Current sweep matrix.
- Alternativamente se puede hacer a través del módulo convencional Multiple Regression si creamos nosotros la variable interacción (Añadir nueva variable "Interacc" y Pulsar sobre su Nombre e incluir la fórmula "=X1*X2" en la ventana Functions).

Interpretación: ¿Se gana en ajuste R² al cambiar a un modelo más complejo?

4.2.3. Análisis detallado mediante regresión. Las tendencias curvilíneas

- Supongamos que nos interesase evaluar una tendencia más compleja, como por ejemplo de orden-3 ó cúbica. El análisis mediante modelización implicaría, entonces los siguientes pasos:

Perspectiva global:
$$\left\{ \begin{array}{l} AMP : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 \\ COM : \widehat{Y}_i = \beta_0 \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : R^2 = 0 \\ H_1 : R^2 \neq 0 \end{array} \right\}$$

Perspectiva Condicional:

Lineal u orden-1
$$\left\{ \begin{array}{l} AMP : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 \\ COM : \widehat{Y}_i = \beta_0 + \beta_2 X_i^2 + \beta_3 X_i^3 \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : \beta_1 = 0 \\ H_1 : \beta_1 \neq 0 \end{array} \right\}$$

Cuadrática u orden-2
$$\left\{ \begin{array}{l} AMP : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 \\ COM : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_3 X_i^3 \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : \beta_2 = 0 \\ H_1 : \beta_2 \neq 0 \end{array} \right\}$$

Cúbica u orden-3:
$$\left\{ \begin{array}{l} AMP : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 \\ COM : \widehat{Y}_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 \end{array} \right\} \equiv \left\{ \begin{array}{l} H_0 : \beta_3 = 0 \\ H_1 : \beta_3 \neq 0 \end{array} \right\}$$

Analizar → Regresión → Estimación curvilínea → Dependientes: Y; Independiente: X1; Modelos: Lineal, Cuadrático, Cúbico → Aceptar.
 Statistics → Advanced Linear/NonLinear → General Linear Models → Polynomial Regression → Una vez definidas las variables, el Botón Between Effects permite ampliar la complejidad del modelo polinómico.

Interpretación: ¿Se gana en ajuste R² al cambiar a un modelo más complejo? Tener presentes indicaciones sobre especificidad de la Hipótesis (crear los modelos mediante opción de Datos, Calcular).

Conclusión: Probar con los diferentes Modelos, omitiendo predictores no significativos o problemáticos hasta dejar un Modelo Final.

Interpretación: Especifique el modelo final:

4.2.4. El caso general: análisis de regresión de modelos complejos

- En concreto, se usa un método de regresión interactivo “regresión paso a paso” (**stepwise regression**) que va incorporando (“forward”) o eliminando (“backward”) sucesivamente variables.
- El objetivo general es explicar un porcentaje de varianza del criterio similar al explicado por el total de predictores.
- Se fija un nivel de significación, lo que impone un umbral de inclusión de variables.
- En el método incremental, se calculan las correlaciones de todos los predictores con el criterio y se selecciona la variable con mayor correlación, siempre que supera el umbral de inclusión.
- A continuación se elige el siguiente mejor predictor pero según la correlación semiparcial para controlar la influencia del predictor que ya estaba en el modelo y siempre que vuelva a superar el umbral.
- Así sigue el procedimiento hasta que el incremento en correlación múltiple deja de ser significativo, es decir no sobrepasa el umbral.
- La otra variante opera a la inversa.
- El problema es que si los predictores son redundantes (recordar los conceptos asociados como tolerancia o tasa de Inflación), entonces el algoritmo implementado por algunos programas especializados no lleva a modelos realmente óptimos.
- Además, la interpretación del modelo resultante puede ser difícil. Siempre es preferible realizar un análisis guiado por hipótesis de investigación que doten de sentido a los resultados del análisis estadístico.
- Si la investigación incluye muchos predictores estará claramente enfocada desde el punto de vista correlacional y será preferible realizar los análisis dentro de la perspectiva especializada de “**análisis causal**”, en la que se corrige el problema de “colinealidad”.
- Además de lo anterior, existe la posibilidad de plantear modelos complejos con interacciones y polinomios, lo que se analiza mediante Modelos de regresión de superficie (i.e. Response Surface Regression dentro del módulo GLM de Statística).

Supuesto 1

Analizar → Regresión → lineal →
 Dependiente: Y; Independientes: X1,
 X2, X3, X4; Método: Hacia adelante →
 Aceptar

Statistics → Multiple Regression
 → Variables: Dependent: FreqY;
 Independent: X1-X4 → *Pestaña*
 Advanced → Marcar Advanced options
 (stepwise ...) → OK → Method:
 Forward stepwise → OK.

➤ Probar con otras variantes
 buscando convergencia, i.e. Hacia
 atrás (backward).

Interpretación:

Hacia delante y hacia atrás consideran las variables una a una.


En los métodos introducir y borrar se consideran bloques de variables.

Pasos sucesivos realiza convergentemente la introducción y la eliminación.

4.3. Alternativas robustas y No paramétricas de regresión

- ✓ Línea resistente de Tukey y Reajuste de los parámetros mediante un método iterativo de Emerson y Hoaglin (1985)

Figura 4-1: Interpretación gráfica del parámetro de tasa de cambio en regresión robusta



- ✓ Alternativa basada en los MM-Estimadores de regresion
- ✓ Alternativa No paramétrica basada en la prueba de Brown-Mood

Ver para todas ellas el manual general recomendado y se ilustrarán en la última sesión.

4.4. Opciones de Regresión Lineal en los paquetes de Análisis

- Probablemente, paquetes como SPSS tienen ventajas en cuanto al análisis de Modelos complejos a partir de la opción de regresión por pasos.
- En cambio, paquetes como Statistica son preferibles desde el punto de vista de la Modelización.
- Otros paquetes como S-Plus son la opción para Regresión Robusta.

4.4.1. Opciones de Regresión Lineal en SPSS 12.0/15.0

Regresión lineal: Estadísticos

Coeficientes de regresión
 Estimaciones
 Intervalos de confianza
 Matriz de covarianza

Ajuste del modelo
 Cambio en R cuadrado
 Descriptivos
 Correlaciones parcial y semiparcial
 Diagnósticos de colinealidad

Residuos

Durbin-Watson
 Diagnósticos por caso

Valores atípicos a más de desviaciones típicas
 Todos los casos

Regresión lineal: Gráficos

Dispersión 1 de 1

DEPENDENT

- *ZPRED
- *ZRESID
- *DRESID
- *ADJPRED
- *SRESID
- *SDRESID

Y:

X:

Gráficos de residuos tipificados
 Histograma
 Gráfico de prob. normal

Generar todos los gráficos parciales

Regresión lineal: Guardar nuevas variables

Valores pronosticados

- No tipificados
- Tipificados
- Corregidos
- E.T. del pronóstico promedio

Residuos

- No tipificados
- Tipificados
- Estudentizados
- Eliminados
- Eliminados estudentizados

Distancias

- Mahalanobis
- De Cook
- Valores de influencia

Estadísticos de influencia

- DiBetas
- DiBetas tipificadas
- DiAjuste
- DiAjuste tipificado
- Razón entre covarianzas

Intervalos de pronóstico


- Media Individuos
- Intervalo de confianza: %

Guardar en archivo nuevo

Estadísticos de los coeficientes



Exportar información del modelo al archivo XML

4.4.2. Opciones de Regresión Lineal en Statistica



A) Aproximación clásica

B) Aproximación Modelización



A) Aproximación clásica (Regresión Múltiple):

The image shows two SPSS dialog boxes. The left one is the 'Multiple Linear Regression: CADIP11_Sup1E.st' dialog, and the right one is the 'Multiple Regression Results: CADIP11_Sup1E.sta' results window.

Multiple Linear Regression Dialog:

- Quick | Advanced | OK | Cancel | Options
- Variables: Variables
- Dependent: none
- Independent: none
- Input file: Raw Data
- Advanced options (stepwise or ridge regression)
- Review descriptive statistics, correlation matrix
- Extended precision computations
- Batch processing/reporting
- Print/report residual analysis
- Specify all variables for the analysis; additional models (indep./dep. vars) can be specified later. For stepwise regression etc. check the advanced options check box.
- See also the General Regression Models (GRM) module.
- Weighted moments: Weighted moments
- DF = W:1 N:1
- MD deletion: Casewise, Pairwise, Mean substitution

Multiple Regression Results:

Multiple Regression Results

Dependent: FREQU Multiple R = ,75889856 F = 4,413775
 R² = ,57592703 df = 4,13
 No. of cases: 18 adjusted R² = ,44544303 p = ,017967
 Standard error of estimate: 22,958284724
 Intercept: 291,11843450 Std. Error: 178,3047 t(13) = 1,6327 p = ,1265

X1 beta=-1,9 X2 beta=-,04 X3 beta=-,44
 X4 beta=-,89

(significant betas are highlighted)

Alpha for highlighting effects: ,05

Quick | Advanced | Residuals/assumptions/prediction | OK | Cancel | Options

Summary: Regression results

B) Aproximación Modelización (Modelo Lineal General –GLM-):

The image shows two SPSS dialog boxes. The left one is the 'GLM Results 1: CADIP11_Sup1E.sta' dialog, and the right one is the 'GLM Results 1: CADIP11_Sup1E.sta' results window.

GLM Results Dialog:

- Residuals 1 | Residuals 2 | Matrix | Report | Less | Close | Modify | Options
- Summary | Assumptions | Profiler | Custom tests
- All effects/Graphs | Test all effects
- Univariate results | Descriptive cell statistics
- Between effects: Design terms, Whole model R, Coefficients, Estimate
- Alpha values: Conf.: ,950, Signif.: ,050

GLM Results:

Summary | Assumptions | Profiler | Custom tests | Residuals 1 | Residuals 2 | Matrix | Report | Less | Close | Modify | Options

Dependent variables: FREQU

Show predicted and residual values: Predicted and residuals, Standardized stats

Sort obs by: Case numbers

Probab. plots of resid: Normal, Half-normal, Plot absolute values, Detrended

Save: Pred. & resid, Obs. & pred, Obs. & resid, Res. & def. res, Case no. & res

4.5. Realización de los supuestos de prácticas

Guía del análisis en Regresión

- Análisis exploratorio de los diagramas de dispersión
- Análisis del modelo SATURADO de referencia
- Análisis de los residuales (estandarizados) y de las distancias de influencia indebida para decidir sobre los posibles puntos extremos.
- Confirmar conclusiones de significación para cada predictor mediante regresión por pasos.
- Si gráficos de residuales sugieren funciones curvilíneas entonces pasar al análisis polinómico (regresión curvilínea).
- Incluir interacciones si están justificadas desde el punto de vista teórico.

4.5.1. Ejemplificación del análisis de Regresión mediante el Supuesto 1

[Gráficos|Dispersión...] o mejor **[Gráficos|Interactivos|Dispersión ...]** para ajustar la línea de regresión lineal.

Los diagramas de dispersión de cada predictor frente al criterio

Análisis del modelo SATURADO de referencia, es decir el que incluye todos los predictores (X1 a X4) y de manera lineal.

[Analizar|Regresión lineal] Seleccionamos las opciones de Estadísticos, Gráficos y Guardar que aparecen en las ventanas precedentes...

Análisis de los residuales

Observar al menos los gráficos de RRESID frente a ADJPRED, incluyendo los gráficos parciales y el de probabilidad normal

Confirmarlo a partir de las Distancias de Cook.

El caso 8 parece tener un error estandarizado muy elevado pero puesto que está justificado, entonces no se omitiría

Confirmar las conclusiones de los parámetros significativos (únicamente la inversa de la variable predictora X1) mediante regresión por pasos, por ejemplo introduciendo variables en pasos sucesivos.

Probar Modelo polinómico

[Analizar|Regresión|Estimación curvilínea ...]

La pregunta clave es ¿Se gana en ajuste R^2 al cambiar a un modelo más complejo que el lineal?

Centrar el modelo significativo y resumirlo adecuadamente.

[Volver Principio](#)
