

## Modelos no paramétricos y de regresión/Estadística II | Semestre 2018-1

*Proyecto modelos de regresión*

Fecha de entrega: 24 de noviembre

El objetivo es modelar el ingreso corriente en los hogares de los municipios del país a partir un conjunto de variables sociodemográficas relevantes.

- ENT: Clave de la entidad
- Entidad: porcentaje de población de 6 a 14 años que no asiste a la escuela.
- MUN: porcentaje de población de 15 años y más con educación básica incompleta.
- Municipio: porcentaje de viviendas particulares habitadas con piso de tierra.
- Alf: porcentaje de población de 15 o más años que sabe leer y escribir.
- Asi: porcentaje de población de 6 a 14 años que asiste a la escuela.
- EBC: porcentaje de población de 15 o más años con educación básica completa.
- Der: porcentaje de población con derechohabiencia a servicios de salud.
- Pis: porcentaje de viviendas particulares habitadas con piso diferente de tierra.
- San: porcentaje de viviendas particulares habitadas que disponen de excusado o sanitario.
- Agu: porcentaje de viviendas particulares habitadas que no disponen de agua potable.
- Dre: porcentaje de viviendas particulares habitadas que no disponen de drenaje.
- Ele: porcentaje de viviendas particulares habitadas que no disponen de electricidad.
- Lav: porcentaje de viviendas particulares habitadas que disponen de lavadora.
- Ref: porcentaje de viviendas particulares habitadas que disponen de refrigerador.
- Ing: Estimación de la media del ingreso corriente mensual en los hogares.

Con los datos del archivo [proyecto.csv](#), responder lo siguiente.

1. Hacer un análisis exploratorio pertinente:

- a) Explorar la asociación lineal entre las variables con *corrplot*.
- b) Explorar la dispersión de cada variable con *boxplots*.
- c) Interpretar los resultados.

2. Ajustar un modelo RLM tomando como respuesta la variable Ing.

- a) Reportar las estimaciones, puntuales y por intervalo, de los parámetros del modelo.
- b) Reportar la significancia individual y conjunta (ANOVA) de las variables incluidas.
- c) Reportar los coeficientes  $R^2$  y  $R^2_{adj}$ .

3. Multicolinealidad

- a) Calcular la matriz de correlaciones y presentarla como *corrplot*.
- b) Calcular índice de condición  $\kappa$  de la matriz  $\mathbf{X}^T \mathbf{X}$ .
- c) Calcular los factores de inflación de la varianza de cada variable explicativa.
- d) A partir de los resultados anteriores, concluir si existen problemas de multicolinealidad.

- e) Si es el caso, proponer y aplicar las medidas correctivas que se consideren necesarias.
  - f) Si es el caso, validar que el problema de multicolinealidad se haya corregido.
  - g) Si es el caso, ajustar nuevamente el modelo incorporando las correcciones aplicadas.
4. Validar el supuesto de linealidad.
- a) Hacer gráficos de residuos parciales para cada variable.
  - b) Hacer pruebas de falta de ajuste (*lack-of-fit*) para cada variable.
  - c) Hacer una prueba de no aditividad de Tukey.
  - d) A partir de los resultados anteriores, concluir si existen desviaciones graves al supuesto de linealidad.
  - e) Si es el caso, proponer y aplicar las medidas correctivas que se consideren necesarias y validar que el problema de no linealidad se haya corregido.
  - f) Si es el caso, ajustar nuevamente el modelo incorporando las correcciones aplicadas.
  - g) Si es el caso, explorar nuevamente los supuestos anteriores y ajustar de nuevo el modelo incorporando las correcciones aplicadas.
5. Validación del supuesto de homocedasticidad.
- a) Graficar los residuos contra cada variable explicativa.
  - b) Hacer una prueba de Breusch-Pagan.
  - c) Hacer una prueba de White.
  - d) A partir de los resultados anteriores, concluir si existen desviaciones graves al supuesto de linealidad.
  - e) Si es el caso, proponer y aplicar las medidas correctivas que se consideren necesarias y validar que las desviaciones al supuesto de homocedasticidad se hayan corregido.
  - f) Si es el caso, ajustar nuevamente el modelo incorporando las correcciones aplicadas.
  - g) Si es el caso, explorar nuevamente los supuestos anteriores y ajustar de nuevo el modelo incorporando las correcciones aplicadas.
6. Validar el supuesto de normalidad.
- a) Presentar un histograma de los residuos estudentizados.
  - b) Presentar un `QQplot` de los residuos estudentizados.
  - c) Aplicar alguna prueba de normalidad (K-S, A-D, etc.)
  - d) A partir de los resultados anteriores, concluir si existen desviaciones graves al supuesto de linealidad.
  - e) Si es el caso, proponer y aplicar las medidas correctivas que se consideren necesarias y validar que las desviaciones al supuesto de normalidad se hayan corregido.
  - f) Si es el caso, ajustar nuevamente el modelo incorporando las correcciones aplicadas.
  - g) Si es el caso, explorar nuevamente los supuestos anteriores y ajustar de nuevo el modelo incorporando las correcciones aplicadas.
7. Explorar la presencia de observaciones atípicas e influyentes.
- a) Utilice las entradas de la matriz  $\mathbf{H}$  para identificar observaciones influyentes.

- b) Utilice los DFFITS y DFBETAS para identificar observaciones influyentes.
- c) Utilice los residuales estudentizados para identificar observaciones atípicas.
- d) A partir de los resultados anteriores, decida si hay presencia de observaciones atípicas o de observaciones influyentes, de ser el caso decida que medidas correctivas aplicar y valide que el problema se haya resuelto.
- e) Si es el caso, ajustar nuevamente el modelo incorporando las correcciones aplicadas.
- f) Si es el caso, explorar nuevamente los supuestos anteriores y ajustar de nuevo el modelo incorporando las correcciones aplicadas.

8. Del último modelo ajustado:

- a) Reportar las estimaciones, puntuales y por intervalo, de los parámetros del modelo.
- b) Reportar la significancia individual y conjunta (ANOVA) de las variables incluidas.
- c) Reportar los coeficientes  $R^2$  y  $R_{adj}^2$ .
- d) Comparar estos resultados con los obtenidos en el punto 2. ¿Mejoró el ajuste del modelo?

9. Interpretar los resultados en el contexto de los datos.

- a) ¿Qué variables tienen algún efecto para modelar el ingreso en los hogares?
- b) ¿Qué variable tiene el mayor efecto? ¿Qué variable tiene el mejor efecto?
- c) ¿Qué signos tienen los  $\beta$ s y qué interpretación tienen estos signos?
- d) ¿La varianza del modelo permite obtener *buenas* predicciones?