

# Variables Instrumentales

Maestría en Economía Uninorte

Carlos Andrés Yanes

2024-08-24

## Preambulo

Los modelos de **variables instrumentales** (IV) son una técnica econométrica crucial cuando se enfrentan problemas de endogeneidad en la estimación de relaciones causales. En la evaluación de impacto, la endogeneidad surge cuando una o más variables explicativas están correlacionadas con el término de error, lo que sesga los estimadores y dificulta identificar efectos causales verdaderos.

### ¿Qué es la endogeneidad?

La endogeneidad puede surgir por varias razones, como la presencia de variables omitidas, la simultaneidad, o el error de medición. Por ejemplo, al evaluar el impacto de la educación en los ingresos, es posible que factores no observados como la habilidad innata o el entorno familiar influyan tanto en la educación como en los ingresos, generando una correlación entre la educación y el término de error.

### ¿Qué son las Variables Instrumentales?

Las variables instrumentales se utilizan para resolver este problema. Una variable instrumental es una variable que está correlacionada con la variable explicativa endógena pero que no está correlacionada con el término de error. En otras palabras,

el instrumento afecta el resultado solo a través de su impacto en la variable endógena.

Supongamos que estamos interesados en medir el impacto de una intervención educativa en los salarios futuros. Si los individuos que eligen participar en la intervención son aquellos más motivados o con más recursos, la simple estimación de una regresión lineal podría sobreestimar el impacto de la intervención debido a la selección no aleatoria. Aquí es donde un buen instrumento es vital.

Si encontramos un instrumento válido, como una política de expansión educativa que no está directamente relacionada con los salarios futuros, podemos utilizarlo para estimar el impacto causal de la educación en los ingresos, aislando el efecto de la endogeneidad.

#### Cuidado

La base de datos para este modulo solo será enviada por correo electronico a los estudiantes del curso de Econometría de la Universidad del Norte

## Datos

- Fuente original es de Jeffrey R. Kling (2001).
- El artículo se llama: “Interpreting Instrumental Variables Estimates of the Returns to Schooling”. *Journal of Business and Economic Statistics*, 19, 358-364.
- Tiene que ver con los retornos de la educación<sup>1</sup>

## Limpiando el Environment de R

```
rm(list = ls())
```

<sup>1</sup> Hemos insistido en los temas de educación ya que existe una amplia literatura en la implementación de este tipo de **instrumentos** para una correcta estimación

## Preparación del entorno para ejecución

Primero que nada preparar los paquetes que se van a usar para realizar el ejercicio. Estos permitirán usar las funciones para los cálculos pertinentes

```
library(pacman)
p_load(lmtest, foreign, haven, tidyverse, stargazer, dplyr, estimatr, ggplot2, sandwich)
```

## Cargar la base de datos

Del archivo proporcionado y utilizando a `haven` procedemos a importar la base

```
base.ed <- read_dta("Returnseducational.dta")
head(base.ed)
```

```
# A tibble: 6 x 101
  id black imigrnt hhead mag_14 news_14 lib_14 num_sib fgrade mgrade iq
  <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl>
1     2     1     0     1     0     1     0     7     NA     NA     NA
2     3     0     0     1     1     1     1     1     8     8     93
3     4     0     0     1     1     1     1     2    14    12    103
4     5     0     0     1     0     1     1     NA    11    12     88
5     6     0     0     1     0     1     0     0     8     7    108
6     7     0     0     1     1     1     1     NA     9    12     85
# i 90 more variables: bdate <dbl>, gfill76 <dbl>, wt76 <dbl>, grade76 <dbl>,
# grade66 <dbl>, age66 <dbl>, smsa66 <dbl>, region <dbl>, smsa76 <dbl>,
# col4 <dbl>, mcol4 <dbl>, col4pub <dbl>, south76 <dbl>, wage76 <dbl>,
# exp76 <dbl>, expsq76 <dbl>, age76 <dbl>, agesq76 <dbl>, reg1 <dbl>,
# reg2 <dbl>, reg3 <dbl>, reg4 <dbl>, reg5 <dbl>, reg6 <dbl>, reg7 <dbl>,
# reg8 <dbl>, reg9 <dbl>, momdad14 <dbl>, sinmom14 <dbl>, nodaded <dbl>,
# nomomed <dbl>, daded <dbl>, momed <dbl>, famed <dbl>, famed1 <dbl>, ...
```

## Etiquetas

La base de datos de acuerdo a las columnas de datos podemos decir de cada una de ellas lo siguiente:

Variable	Tipo	Etiqueta de la Variable
wage76	float	Salario en el '76
grade76	float	Nivel educativo en el '76
col4	float	Si hay alguna universidad de 4 años cerca
age76	float	Edad en el '76 (edad66 + 10)

## Estadística

```
summary(base.ed[c("wage76", "grade76", "col4", "age76")])
```

wage76	grade76	col4	age76
Min. :0.000	Min. : 1.00	Min. :0.0000	Min. :24.00
1st Qu.:1.372	1st Qu.:12.00	1st Qu.:0.0000	1st Qu.:25.00
Median :1.682	Median :13.00	Median :1.0000	Median :28.00
Mean :1.657	Mean :13.26	Mean :0.6821	Mean :28.12
3rd Qu.:1.958	3rd Qu.:16.00	3rd Qu.:1.0000	3rd Qu.:31.00
Max. :3.180	Max. :18.00	Max. :1.0000	Max. :34.00

## Correlación

Por un momento miremos la correlación que existe entre este par de variables. El **objetivo** es mirar si existe relación entre ellas, es una especie de tener presente que no vayamos a tener Este es un texto normal y multicolinealidad en el modelo.

```
# Correlación
cor(base.ed$grade76, base.ed$col4)
```

```
[1] 0.1442402
```

## Primer modelo de estimación

Vamos a mirar el resultado de la estimación

```
ols_model <- lm(wage76 ~ grade76 + age76, base.ed)
coeftest(ols_model, vcov = vcovHC(ols_model, type = "HC"))
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-0.1830865	0.0772381	-2.3704	0.01783	*
grade76	0.0525110	0.0027812	18.8808	< 2e-16	***
age76	0.0406575	0.0023938	16.9848	< 2e-16	***

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Denotando que el Número de años que llevaba aprobados hasta el año 76 genera un impacto en el salario bastante significativo. A medida que esto aumenta en un año adicional el salario también aumenta.

## Guardar el modelo MCO

A continuación con el objetivo de hacer una comparación adecuada de modelos vamos a ir guardando las salidas correspondientes en objetos para darle una forma mas adecuada y con ellos tener una mejor interpretabilidad

```
ols_model <- lm(wage76 ~ grade76 + age76, data = base.ed)
```

## Modelo IV usando la función ivreg del paquete AER

Empecemos a instrumentar, la idea parte de decir que el hecho de que una universidad este cerca a un individuo incide en su escolaridad o tomar una elección de hacerlo pero no tiene nada que ver con el salario que percibe. La edad también se convierte en otro instrumento clave. La edad es un factor decisivo para de alguna manera tomar la decisión de escolarizarse y solo

en algunas veces puede incidir algo en el salario debido a políticas que puedan tener las empresas pero no debería darnos problemas adicionales.

```
library(AER)
iv_model <- ivreg(wage76 ~ grade76 + age76 | col4 + age76, data = base.ed)
summary(iv_model, vcov = sandwich)
```

Call:

```
ivreg(formula = wage76 ~ grade76 + age76 | col4 + age76, data = base.ed)
```

Residuals:

Min	1Q	Median	3Q	Max
-2.06376	-0.33914	0.01597	0.34869	2.04965

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-1.819567	0.334451	-5.440	5.74e-08	***
grade76	0.173973	0.024236	7.178	8.85e-13	***
age76	0.041563	0.003019	13.767	< 2e-16	***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.5168 on 3007 degrees of freedom

Multiple R-Squared: -0.3554, Adjusted R-squared: -0.3563

Wald test: 118.3 on 2 and 3007 DF, p-value: < 2.2e-16

Los resultados son homocedásticos al aplicar la corrección tipo `sandwich` para corregir problemas de varianza no constante.

## Tabla de comparaciones entre MCO y IV

Vamos hacer la comparación entre modelos para ver que diferencias tienen los resultados. El paquete `stargazer` ayuda a darle visibilidad a los datos

```

library(stargazer)
stargazer(ols_model, iv_model, type = "text",
  keep = c("grade76"), digits = 4,
  se = list(coeftest(ols_model, vcov = vcovHC(ols_model, type = "HC"))[, 2],
    sqrt(diag(vcovHC(iv_model, type = "HC")))),
  dep.var.labels = "Salario en el 76'", covariate.labels = "Años aprobados 76'")

```

```

=====
                                Dependent variable:
-----
                                Salario en el 76'
                                OLS                instrumental
                                (1)                variable
                                (2)
-----
Años aprobados 76'                0.0525***          0.1740***
                                (0.0028)            (0.0242)
-----
Observations                3,010                3,010
R2                0.1813                -0.3554
Adjusted R2        0.1808                -0.3563
Residual Std. Error (df = 3007)  0.4017                0.5168
F Statistic                333.0018*** (df = 2; 3007)
=====
Note:                *p<0.1; **p<0.05; ***p<0.01

```

Note la diferencia que existe en el estimador IV. Al parecer estábamos **sobreestimando** el efecto que tiene la educación en el salario de los individuos.

### Estimación del estimador IV en dos etapas

Miremos esto por fases o etapas<sup>2</sup> que consideramos importante en la estimación del modelo

<sup>2</sup> Son los comunmente conocidos Modelos 2LS (Two least Square) o Bi-etapicos.

## Primera etapa: regresión OLS para obtener la predicción

Corremos un modelo donde se intenta explicar la educación con los controles sugeridos

```
first_stage <- lm(grade76 ~ col4 + age76, data = base.ed )
base.ed$grade76hat <- predict(first_stage)
```

## Segunda etapa: regresión OLS con el valor predicho

Estimamos el modelo pero con la educación estimada ( $\hat{educ}$ )

```
ols_two_stage <- lm(wage76 ~ grade76hat + age76, data = base.ed)
coefest(ols_two_stage, vcov = vcovHC(ols_two_stage, type = "HC"))
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-1.8195667	0.2742206	-6.6354	3.823e-11	***
grade76hat	0.1739731	0.0200007	8.6983	< 2.2e-16	***
age76	0.0415634	0.0024976	16.6415	< 2.2e-16	***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

## Repetir el análisis con más controles

Recordemos que podemos adherir un número mayor de controles<sup>3</sup> sobre nuestra estimación. Para eso, primero crearemos una lista o `list`, eso con el objeto de no tener una fórmula muy larga en la línea de comandos. Luego usamos la función de `as.formula` y luego se corre.

```
# Crear una lista de variables independientes
regresores <- c("south76", "smsa76", "reg2", "reg3", "reg4", "reg5", "reg6", "reg7", "reg8", "1")

## Acá los juntamos todos
formula <- as.formula(paste("wage76 ~", paste(regresores, collapse = " + ")))
```

<sup>3</sup> El conjunto controles son muchas variables “categoricas” que contienen valores de 1 o 0, para aquellas características de si vive en cierta region (reg), si vive en el sur (south76), si vive en área metropolitana. Con la opción `View` están mejor clarificadas



```
# Estimamos el modelo con todos los controles
ols_model_controls <- lm(formula, data = base.ed)
coeftest(ols_model_controls, vcov = vcovHC(ols_model_controls, type = "HC"))
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	1.2428234	0.0857897	14.4869	< 2.2e-16	***
south76	-0.1445395	0.0308281	-4.6886	2.875e-06	***
smsa76	0.1386612	0.0212900	6.5130	8.615e-11	***
reg2	0.0776287	0.0384625	2.0183	0.0436497	*
reg3	0.1197300	0.0367253	3.2601	0.0011261	**
reg4	0.0529788	0.0429885	1.2324	0.2178982	
reg5	0.0321178	0.0458129	0.7011	0.4833165	
reg6	0.0256598	0.0486610	0.5273	0.5980128	
reg7	0.0446355	0.0493165	0.9051	0.3654948	
reg8	-0.0190857	0.0542837	-0.3516	0.7251694	
reg9	0.1353619	0.0425367	3.1822	0.0014764	**
smsa66	0.0424718	0.0207877	2.0431	0.0411282	*
momdad14	0.1519061	0.0276634	5.4912	4.326e-08	***
sinmom14	0.0192168	0.0395725	0.4856	0.6272796	
nodaded	-0.0663376	0.0542202	-1.2235	0.2212431	
nomomed	0.0035360	0.0378875	0.0933	0.9256489	
daded	0.0080566	0.0048607	1.6575	0.0975265	.
momed	0.0156137	0.0045005	3.4693	0.0005292	***
famed1	-0.1584073	0.0868107	-1.8247	0.0681396	.
famed2	-0.0734555	0.0756583	-0.9709	0.3316846	
famed3	-0.1117697	0.0696830	-1.6040	0.1088258	
famed4	0.0677970	0.0477179	1.4208	0.1554828	
famed5	-0.0754945	0.0672963	-1.1218	0.2620280	
famed6	-0.0809125	0.0654690	-1.2359	0.2165971	
famed7	-0.1272778	0.0695159	-1.8309	0.0672128	.
famed8	-0.0854991	0.0593577	-1.4404	0.1498580	

---  
 Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

## Modelo IV con más controles

De la misma forma como se hizo anteriormente vamos a instrumentar nuestro modelo, haciendo uso de los instrumentos dispuestos para ello  $z = \{col4, age76\}$ .

```
formula_iv <- as.formula(paste("wage76 ~ grade76 +",
                              paste(regresores, collapse = " + "),
                              "| col4 +",
                              paste(regresores, collapse = " + ")))

# Ajustar el modelo IV
iv_model_controls <- ivreg(formula_iv, data = base.ed)
summary(iv_model_controls, vcov = sandwich)
```

Call:

```
ivreg(formula = formula_iv, data = base.ed)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-1.82689	-0.27226	0.02088	0.28000	1.42205

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	0.408944	0.443146	0.923	0.35618	
grade76	0.102552	0.053324	1.923	0.05455	.
south76	-0.131382	0.031430	-4.180	3e-05	***
smsa76	0.060411	0.046635	1.295	0.19528	
reg2	0.037715	0.045200	0.834	0.40411	
reg3	0.082576	0.043468	1.900	0.05757	.
reg4	-0.005886	0.055586	-0.106	0.91568	
reg5	0.031876	0.047325	0.674	0.50064	
reg6	0.030389	0.049921	0.609	0.54274	
reg7	0.015680	0.052746	0.297	0.76627	
reg8	-0.091339	0.067261	-1.358	0.17457	
reg9	0.073415	0.054004	1.359	0.17411	
smsa66	0.066245	0.024507	2.703	0.00691	**
momdad14	0.104967	0.038218	2.747	0.00606	**
sinmom14	0.008422	0.041196	0.204	0.83802	
nodaded	-0.064221	0.057085	-1.125	0.26068	

```

nomomed      0.029217   0.040729   0.717   0.47321
daded        -0.009247   0.010283  -0.899   0.36857
momed        -0.002514   0.010504  -0.239   0.81087
famed1       -0.287469   0.112147  -2.563   0.01042 *
famed2       -0.225740   0.111728  -2.020   0.04343 *
famed3       -0.202399   0.087057  -2.325   0.02014 *
famed4       -0.026049   0.068230  -0.382   0.70265
famed5       -0.139581   0.077837  -1.793   0.07304 .
famed6       -0.150518   0.077045  -1.954   0.05084 .
famed7       -0.173131   0.076272  -2.270   0.02328 *
famed8       -0.159091   0.071819  -2.215   0.02682 *

```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.4274 on 2983 degrees of freedom  
Multiple R-Squared: 0.08057, Adjusted R-squared: 0.07255  
Wald test: 21.83 on 26 and 2983 DF, p-value: < 2.2e-16

## Tabla de comparaciones entre OLS y IV con más controles

Una salida general a todo esto que hemos realizado nos da como resultado<sup>4</sup> un modelo en un formato de estilo mas científico

```

stargazer(ols_model_controls, iv_model_controls, type = "text",
  keep = c("grade76"), digits = 4,
  dep.var.labels = "wage76", covariate.labels = "grade76")

```

<sup>4</sup> La sobreidentificación se hace con una prueba F, comparando dos tipos de modelos. Uno con todos los regresores y otro sin ellos, al ver la significancia podemos entonces concluir que no tenemos sobreidentificación.

```

=====
                        Dependent variable:
-----
                                wage76
                                OLS      instrumental
                                (1)      variable
                                (2)
-----
grade76                                0.1026*
                                         (0.0550)

```

```

-----
Observations                3,010                3,010
R2                          0.1570                0.0806
Adjusted R2                  0.1499                0.0726
Residual Std. Error    0.4092 (df = 2984)    0.4274 (df = 2983)
F Statistic              22.2239*** (df = 25; 2984)
=====
Note:                        *p<0.1; **p<0.05; ***p<0.01

```

### Diagnóstico de instrumentos débiles: correlación y regresión

Para verificar relevancia de los instrumentos podemos estimar entonces

```
cor(base.ed$grade76, base.ed$col4)
```

```
[1] 0.1442402
```

```
first_stage_diagnostic <- lm(grade76 ~ col4 + age76, data = base.ed)
summary(first_stage_diagnostic)
```

Call:

```
lm(formula = grade76 ~ col4 + age76, data = base.ed)
```

Residuals:

```

      Min       1Q   Median       3Q      Max
-11.6845  -1.5549  -0.5801   2.4325   5.3786

```

Coefficients:

```

              Estimate Std. Error t value Pr(>|t|)
(Intercept) 13.05037    0.43882  29.740 < 2e-16 ***
col4         0.83256    0.10379   8.021 1.49e-15 ***
age76       -0.01262    0.01541  -0.819  0.413
---

```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 2.65 on 3007 degrees of freedom

Multiple R-squared: 0.02102, Adjusted R-squared: 0.02037  
F-statistic: 32.29 on 2 and 3007 DF, p-value: 1.337e-14

La edad en el año 76 parece no ser relevante, sin embargo en conjunto y mirando la prueba F, podemos entonces decir que si es útil

## Test de instrumentos débiles (Anderson-Rubin Wald test)

El test de Anderson-Rubin evalúa si los coeficientes de las variables instrumentales en la regresión auxiliar (donde las variables instrumentales se utilizan para predecir la variable endógena) son estadísticamente diferentes de cero. Si se rechaza la hipótesis nula, esto indica que los instrumentos son relevantes y, por lo tanto, no son débiles.

```
# Del Paquete de AER  
waldtest(iv_model_controls)
```

Wald test

```
Model 1: wage76 ~ grade76 + south76 + smsa76 + reg2 + reg3 + reg4 + reg5 +  
  reg6 + reg7 + reg8 + reg9 + smsa66 + momdad14 + sinmom14 +  
  nodaded + nomomed + daded + momed + famed1 + famed2 + famed3 +  
  famed4 + famed5 + famed6 + famed7 + famed8 | col4 + south76 +  
  smsa76 + reg2 + reg3 + reg4 + reg5 + reg6 + reg7 + reg8 +  
  reg9 + smsa66 + momdad14 + sinmom14 + nodaded + nomomed +  
  daded + momed + famed1 + famed2 + famed3 + famed4 + famed5 +  
  famed6 + famed7 + famed8
```

```
Model 2: wage76 ~ 1 | col4 + south76 + smsa76 + reg2 + reg3 + reg4 + reg5 +  
  reg6 + reg7 + reg8 + reg9 + smsa66 + momdad14 + sinmom14 +  
  nodaded + nomomed + daded + momed + famed1 + famed2 + famed3 +  
  famed4 + famed5 + famed6 + famed7 + famed8
```

```
Res.Df Df Chisq Pr(>Chisq)  
1 2983  
2 3009 -26 512.74 < 2.2e-16 ***
```

---

```
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Constatando que los instrumentos utilizados deben estar presente<sup>5</sup>.

## **Agradecimientos**

Mucho de este trabajo se debe a los artículos, recursos (free commons) y material del Profesor Colin Cameron, autor del libro: Microeconometrics Using Stata.

**Carlos Yanes Guerra | Departamento de Economía |  
Universidad del Norte**

<sup>5</sup> La sobreidentificación se hace con una prueba F, comparando dos tipos de modelos. Uno con todos los regresores y otro sin ellos, al ver la significancia podemos entonces concluir que no tenemos sobreidentificación.