

# Capítulo 4

## Análisis de Regresión Múltiple

### 1. Introducción

El Análisis de Regresión Lineal Múltiple nos permite establecer la relación que se produce entre una variable dependiente Y y un conjunto de variables independientes ( $X_1, X_2, \dots, X_k$ ). El análisis de regresión lineal múltiple, a diferencia del simple, se aproxima más a situaciones de análisis real puesto que los fenómenos, hechos y procesos sociales, por definición, son complejos y, en consecuencia, deben ser explicados en la medida de lo posible por la serie de variables que, directa e indirectamente, participan en su concreción.

Al aplicar el análisis de regresión múltiple lo más frecuente es que tanto la variable dependiente como las independientes sean variables continuas medidas en escala de intervalo o razón. No obstante, caben otras posibilidades: (1) también podremos aplicar este análisis cuando relacionemos una variable dependiente continua con un conjunto de variables categóricas; (2) o bien, también aplicaremos el análisis de regresión lineal múltiple en el caso de que relacionemos una variable dependiente nominal con un conjunto de variables continuas.

La anotación matemática del modelo o ecuación de regresión lineal múltiple es la que sigue:

$$Y = a + b_{1x_1} + b_{2x_2} + \dots + b_{n x_n} + e$$

$$\text{presente} = a + b_{1\text{pasado}} + b_{2\text{futuro}} + e$$

en donde:

Y es la variable a predecir;

a,  $b_{1x_1}$ ,  $b_{2x_2}$ ...  $b_{n x_n}$ , son parámetros desconocidos a estimar;

y e es el error que cometemos en la predicción de los parámetros.

Al ocuparnos del análisis lineal bivariado, análisis de regresión simple, vimos como el modelo final resultante podía ser calificado

de un “buen modelo”. Sin embargo, en muchas ocasiones los modelos bivariados o simples pueden verse mejorados al introducir una segunda (tercera, cuarta,...) variable independiente o explicativa. Consideramos que un modelo de regresión lineal simple se ha “mejorado” cuando al introducir en el mismo más variables independientes la proporción de variabilidad explicada se incrementa. Pero ¿qué variables son las que mejor explican el hecho, proceso o fenómeno social objeto de estudio?; o, ¿qué variables no son necesario incluir en el modelo dada su nula o escasa capacidad explicativa? Esta es, sin lugar a dudas, la decisión más importante ligada al análisis de regresión múltiple y la inclusión de este proceso es lo que diferencia, sustancialmente, al análisis de regresión múltiple del de regresión simple.

La exposición de este capítulo se estructura en torno a los siguientes puntos, a saber:

1. Determinación de la bondad de ajuste de los datos al modelo de regresión lineal múltiple.
2. Elección del modelo que con el menor número de variables explica más la variable dependiente o criterio. Para ello exponemos el proceso de “paso a paso” o *stepwise*.
3. Estimación de los parámetros de la ecuación y del modelo o ecuación predictiva.
4. Exposición de los pasos y Cuadro de Diálogo del Análisis de Regresión Lineal (Múltiple) que podemos seguir para la obtención de los estadísticos y las pruebas necesarias citadas en cada uno de los puntos precedentes.

## 2. Elección del modelo: el método “stepwise” o paso a paso

En el análisis de regresión múltiple, los estadísticos, pruebas y análisis que se aplican para determinar la relación y grado de asociación entre una variable dependiente y sus supuestas variables explicativas, así como la estimación de los parámetros de la ecuación, no difieren de los determinados en el análisis de regresión simple. De hecho, una parte del análisis de regresión bivariado se realiza aplicando el cuadro de diálogo específico del análisis de regresión múltiple. La diferencia estriba, pues, en que mientras en el análisis de regresión simple al contar exclusivamente con la relación de un par de variables el proceso se resolvía en un solo paso; en el análisis de regresión múltiple es necesario calcular estadísticos, pruebas y análisis a medida que

vamos introduciendo y/o sacando variables independientes en el modelo.

En el análisis de regresión lineal múltiple la construcción de su correspondiente ecuación se realiza seleccionando las variables una a una, “paso a paso”. La finalidad perseguida es buscar de entre todas las posibles variables explicativas aquellas que más y mejor expliquen a la variable dependiente sin que ninguna de ellas sea combinación lineal de las restantes. Este procedimiento implica que: (1) en cada paso solo se introduce aquella variable que cumple unos criterios de entrada; (2) una vez introducida, en cada paso se valora si alguna de las variables cumplen criterios de salida; y (3), en cada paso se valora la bondad de ajuste de los datos al modelo de regresión lineal y se calculan los parámetros del modelo verificado en dicho paso. El proceso se inicia sin ninguna variable independiente en la ecuación de regresión y el proceso concluye cuando no queda ninguna variable fuera de la ecuación que satisfaga el criterio de selección (garantiza que las variables seleccionadas son significativas) y/o el criterio de eliminación (garantizar que una variable seleccionada no es redundante).

#### 1.- Verificación de los criterios de probabilidad de entrada.

El p-valor asociado al estadístico T, o probabilidad de entrada, nos indica si la información proporcionada por cada una de las variables es redundante. Si éste es menor que un determinado valor crítico, la variable será seleccionada. El SPSS por defecto establece en 0.05 el valor crítico de la probabilidad de entrada.

El criterio de tolerancia puede ser aplicado como un criterio adicional a la probabilidad de entrada. Éste nos ayuda a identificar si alguna de las variables del modelo es una combinación lineal de las restantes. Si dicho valor es próximo a 0, la variable analizada será una combinación lineal de las restantes variables independientes introducidas. Si el valor de la tolerancia se aproxima a 1 puede reducir la parte de la variabilidad de Y no explicada por las restantes. En síntesis, si la tolerancia para una variable es muy pequeña se excluirá del modelo.

#### 2.- Verificación del criterio de probabilidad de salida.

En este caso, si el p-valor asociado al estadístico T, o probabilidad de salida, es mayor que un determinado valor crítico, la variable será eliminada. El SPSS por defecto establece en 0.1 el valor crítico de la probabilidad de salida (nótese que con la fina-

lidad de que una variable no pueda entrar y salir de la ecuación en dos pasos consecutivos, el valor crítico de la probabilidad de salida debe ser mayor que el de la probabilidad de entrada). En el caso práctico que recogemos en los resultados puede apreciarse que las dos variables independientes han superado los criterios de entrada y de salida.

3.- Límite al número de pasos.

Por último, y para evitar que el proceso de selección se convierta en un proceso cíclico se debe establecer un número límite de pasos. Normalmente este límite es el que equivale al doble del número de variables independientes.

### 3. Bondad de ajuste de los datos al modelo de regresión lineal múltiple

En cada paso, en el que se introduce o elimina una variable, se obtienen los estadísticos de bondad de ajuste ( $R$ ,  $R^2$ ,  $R^2$  corregido, error típico de la estimación), el análisis de varianza y la estimación de parámetros considerando las variables introducidas. El SPSS ofrece dos tablas con esta información: en la primera resume los estadísticos de bondad de ajuste y en la segunda nos presenta el análisis de varianza. En ellas se comparan los resultados obtenidos para cada una de las ecuaciones o modelo obtenidos con la secuencia de pasos utilizados. En nuestro ejemplo, y dado que dos han sido las variables incluidas en la ecuación, dos han sido los pasos, dos son los modelos definidos: el primero sólo incluye una variable explicativa, mientras que el segundo utiliza las dos variables independientes.

A continuación exponemos los principales elementos a considerar en el análisis de regresión múltiple. Recordemos que éstos ya se expusieron en el capítulo de regresión simple. Aquí enfatizamos aquellos aspectos que debemos considerar cuando éstos son aplicados en el análisis de regresión múltiple.

1.- Coeficiente de Correlación Múltiple (Múltiple  $R$ ).

Mide la intensidad de la relación entre un conjunto de variables independientes y una variable dependiente. La primera variable que se introducirá en el modelo, primer paso, será aquella que ofrezca una correlación parcial más alta. Para ello es necesario calcular la matriz de correlaciones parciales. En ella

debemos observar: (1) la interrelación entre las variables independientes; y (2), la relación entre cada una de las variables independientes respecto a la dependiente. En el primer caso, los coeficientes deben ser bajos pues, de lo contrario, cabe la posibilidad que entre ellas se produzca multicolinealidad (diferentes variables explican lo mismo de la variable dependiente). Por su parte, en el segundo caso, las relaciones deben ser altas. En nuestro ejemplo, y por lo que respecta a las variables independientes, su correlación no solo es más alta que baja (0,523) sino que además existe relación entre ellas (su significación se encuentra por debajo de 0.05). Por su parte, ambas variables independientes explican a la variable dependiente pero es la primera la que lo hace de forma más intensa. En síntesis, y a tenor de los resultados obtenidos, tanto la p7b como la p7c explican lo mismo de la variable dependiente. Esta es una cuestión que hay que tener en cuenta a la hora de decidir qué variables son las que entran en el modelo.

Los coeficientes de correlación parcial oscilan entre 1 (fuerte asociación lineal positiva: a medida que aumenten los valores de una variable aumentarán los de la otra) y  $-1$  (fuerte asociación lineal negativa: a medida que aumenten los valores de una variable disminuyen los de la otra). Cuando los valores de este estadístico se aproximen a 0 nos estará indicando que entre las dos variables no existe asociación lineal y, en consecuencia, carece de sentido determinar el modelo y/o ecuación de regresión lineal.

Para determinar si la asociación es estadísticamente significativa podemos contrastar la  $H_0$  de que el coeficiente de correlación lineal es igual a 0; o lo que es lo mismo, que las dos variables están incorrelacionadas. Si el *p-valor* asociado al estadístico de contraste (*r*) es menor que el nivel de significación elegido (normalmente 0.05) rechazaremos  $H_0$ . En la matriz de correlaciones se recogen estos dos valores: en primer lugar aparece el grado de relación (coeficiente de correlación parcial) que se produce entre las dos variables que cruzamos; y en segundo lugar, la significación estadística de esa relación.

La correlación más alta entre el cruce de una variable independiente con la dependiente será el valor de Multiple R que aparezca en el primer paso. En nuestro ejemplo la correlación parcial más alta es la de la variable independiente p7B. Por lo tanto, la primera R que aparece en el primer modelo es 0.871. Además esta correlación es significativa (sig. 0.000).

2.- Coeficiente de Correlación Múltiple al Cuadrado o Coeficiente de Determinación (R Square “ $R^2$ ”).

Mide la proporción (porcentaje si lo multiplicamos por 100) de la variabilidad de la variable dependiente explicada por las variables independiente que en ese momento han sido admitidas en el modelo. A partir del resumen de los modelos generados paso a paso podemos calcular el incremento de  $R^2$ , siendo éste una estimación de la importancia relativa que tiene la variable que acabamos de introducir en el paso correspondiente para predecir la variable dependiente. En nuestro caso el segundo modelo (aquel que considera las dos variables explicativas) mejora al primero (solo considera una variable explicativa). La variabilidad explicada por el primero es del 75% mientras que la del segundo es del 78%. Al introducir una segunda variable se ha mejorado el modelo pues se ha incrementado en un 3% la variabilidad total explicada. Ahora bien, ¿consideramos significativo este incremento hasta el punto de decidir que incluimos esta variable en el modelo?; o por el contrario, ¿es tan insignificante que no cabe introducirlo?; ¿al introducirlo explicamos más con el menor número de variables? La contestación a estos interrogantes varía si nos encontramos ante un modelo con más variables independientes de las consideradas en nuestro ejemplo. En nuestro caso la  $p7c$  no es incluida en el modelo definitivo y, por lo tanto, no formará parte de la ecuación predictiva.

3.- Coeficiente de Determinación Ajustado (Adjusted R Square).

El coeficiente de determinación mide lo mismo que  $R^2$  pero en este caso no queda influenciado por el número de variables que introducimos.

4.- Error Típico de Predicción (ETB).

Por último, el error típico de la predicción nos indica la parte de la variable dependiente que dejamos por explicar. A medida que se incrementa el coeficiente de determinación el error desciende. En nuestro ejemplo, en el primer modelo el ETB es de 1.05 mientras que en el segundo es de 0.99.

5.- Análisis de Varianza.

La tabla de análisis de varianza que incluye en su salida de resultados el SPSS nos permite valorar hasta qué punto es adecuado el modelo de regresión lineal para estimar los valores de la variable dependiente. La tabla de análisis de varianza se basa en que la variabilidad total de la muestra puede descomponerse

entre la variabilidad explicada por la regresión y la variabilidad residual. La tabla de ANOVA proporciona el estadístico F a partir del cual podemos contrastar la  $H_0$  de que  $R^2$  es igual a 0, la pendiente de la recta de regresión es igual a 0, o lo que es lo mismo, la hipótesis de que las dos variables están incorrelacionadas. Si el *p-valor* asociado al estadístico F es menor que el nivel de significación (normalmente 0.05), rechazaremos la hipótesis nula planteada. Del mismo modo podremos considerar que los resultados obtenidos con la muestra son generalizables a la población a la que pertenece la muestra.

En el caso de análisis de regresión múltiple la tabla del análisis de varianza nos indica los *p-valores* asociados al estadístico F en cada uno de los modelos generados.

#### 6.- Análisis de Residuales.

Como ya hemos comentado los residuos, “e”, son la estimación de los verdaderos errores. En regresión lineal la distribución de la variable formada por los residuos debe ser Normal, esto es, los residuos observados y los esperados bajo hipótesis de distribución normal deben ser parecidos. Además, los residuos deben ser independientes. En consecuencia, el análisis de los residuales nos va a permitir no solo profundizar en la relación que se produce entre las variables, sino también, ponderar la bondad de ajuste de la regresión obtenida.

Para contrastar la supuesta normalidad de los residuales podemos recurrir, fundamentalmente, a la representación de dos gráficos: (1) el gráfico de residuales tipificados (*gráfico 1 del anexo de resultados*) nos da idea de cómo se distribuyen los residuos en relación a la distribución normal (que sería la que cabría esperar de los mismos). Si ambas distribuciones son iguales (la distribución de los residuos es normal) los puntos se sitúan sobre la diagonal del gráfico. Por lo contrario, en la medida que aparecen dispersos y formando líneas horizontales respecto a la diagonal, habrá más residuos y el ajuste será peor; (2) el gráfico de probabilidad normal (*gráfico 2 del anexo de resultados*) compara gráficamente, al superponer la curva de distribución normal, la función de distribuciones acumulada observadas en la muestra con la función de distribución acumulada esperada bajo supuestos de normalidad.

Por su parte el estadístico de Durbin-Watson mide el grado de autocorrelación entre el residuo correspondiente a cada obser-

vacación y el anterior (si los residuos son independientes, el valor observado en una variable para un individuo no debe estar influenciado en ningún sentido por los valores de esta variable observados en otro individuo). Si el valor del estadístico es próximo a 2 los residuos están incorrelacionados; si se aproxima a 4, estarán negativamente incorrelacionados; y si se aproximan a 0 estarán positivamente incorrelacionados.

#### 4. Estimación de los parámetros o coeficientes de regresión: la ecuación de predicción o ecuación de regresión múltiple

Una vez que ya hemos analizado el carácter e intensidad de la relación entre las variables, podemos proceder a estimar los parámetros de la ecuación de predicción o de regresión lineal. En el caso del análisis de regresión múltiple tendremos tantas ecuaciones como modelos o pasos hayamos efectuado. De todos ellos elegiremos aquel que mejor se ajuste. Éste es el último de los modelos generados.

El criterio para obtener los coeficientes de regresión  $B_0$ ,  $B_1$  y  $B_2$  es el de mínimos cuadrados. Este consiste en minimizar la suma de los cuadrados de los residuos de tal manera que la recta de regresión que definamos es la que más se acerca a la nube de puntos observados  $y$ , en consecuencia, la que mejor los representa.

Los estadísticos asociados a la variable independiente que a pasado a formar parte del modelo de regresión simple son:

##### 1.- Coeficiente de regresión B.

Este coeficiente nos indica el número de unidades que aumentará la variable dependiente o criterio por cada unidad que aumente la variable independiente.

##### 2.- SEB.

Error típico de B.

##### 3.- Coeficiente Beta.

El coeficiente Beta es el coeficiente de regresión estandarizado. Expresa la pendiente de la recta de regresión en el caso de que todas las variables estén transformadas en puntuaciones Z.



#### 4.- Constante.

El valor de la constante coincide con el punto en el que la recta de regresión corta el eje de ordenadas. En la ecuación de predicción se mantiene constante para todos los individuos. Cuando las variables han sido estandarizadas (puntuaciones Z) o si se utilizan los coeficientes Beta, la constante es igual a 0 por lo que no se incluye en la ecuación de predicción.

#### 5.- Tolerancia.

La tolerancia (T) de una variable en un paso cualquiera del análisis stepwise es la proporción de su varianza intra-grupo no explicada por otras variables del análisis ( $1-R^2$ ). Antes de incluir una variable en el modelo se comprueba que su tolerancia es superior al nivel fijado. Si el valor de la tolerancia de una de las variables independientes es próximo a 0 podemos pensar que ésta es una combinación lineal del resto de variables. Sin embargo, si el valor de T se aproxima a 1, la variable en cuestión puede reducir parte de la varianza no explicada por el resto de variables. Se excluyen del modelo las variables que presentan una tolerancia muy pequeña.

#### 6.- Valor T.

El estadístico T nos permite comprobar si la regresión entre una variable independiente y la dependiente es significativa. Si el *p-valor* asociado al estadístico T (Sig T) es mayor al nivel de significación (normalmente 0.05) rechazaremos que la regresión sea significativa para las dos variables relacionadas.

A tenor de los resultados arrojados sólo nos resta construir la ecuación predictiva. En el ejemplo que se recoge en la sección de Resultados, la transcripción de los resultados a la ecuación quedaría como sigue (al tener las variables la misma escala se toman los coeficientes de B):

$$Y = a + b_1x_1 + e$$

ó

$$\text{presente (p7A)} = 0,51 + 0,87\text{pasado (p7B)} + e$$

En el supuesto caso de que los valores de las variables siguieran una escala diferente, tendríamos que estandarizar utilizando los coeficientes Beta, y no B. Del mismo modo, al contar con la misma escala la constante será cero.

$$\text{presente (p7A)} = 0 + 0,87\text{pasado (p7B)} + e$$

## 5. Cuadro de Diálogo del Análisis de Regresión Múltiple

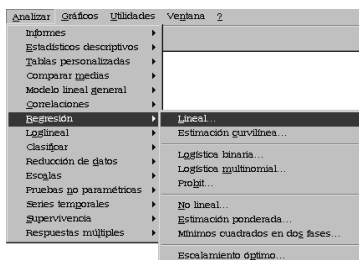


Figura 1

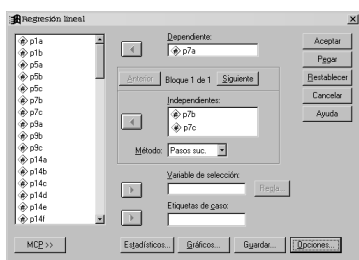


Figura 2




Figura 3



Figura 4

Los pasos para la construcción del modelo son los que siguen.

1<sup>er</sup> paso: Para acceder al Cuadro de Diálogo del Análisis de Regresión Lineal, deberemos seguir Analizar: Regresión: Lineal (figura 1).

2<sup>o</sup> paso: Allí seleccionaremos la variable Dependiente que queremos explicar a partir de un conjunto de variables Independientes. Las variables seleccionadas las pasamos a sus respectivos cuadros (figura 2). En el ejemplo que proponemos las variables seleccionadas han sido las variables continuas p7A SITUACIÓN ACTUAL ESPAÑOLA como variable dependiente o criterio y p7B SITUACIÓN ESPAÑOLA PASADA y p7C SITUACIÓN ESPAÑOLA futura como variables independientes o predictoras.

3<sup>er</sup> paso: En el cuadro principal, y una vez seleccionadas las variables, deberemos elegir el Método que vamos a seguir para la obtención del mejor modelo de regresión lineal. El método de entrada de datos al modelo que vamos a seleccionar es de Pasos sucesivos (o Stepwise) (figura 2).

4<sup>o</sup> paso: Cliqueando en Estadísticos, botón de comando situado en la parte inferior del cuadro de diálogo principal, accedemos a la relación de los principales estadísticos vinculados con el análisis de regresión. Nuestro interés se va a centrar, fundamentalmente, en las opciones: Descriptivos (nos calcula la media y desviación típica de cada una de las variables que introducimos, nos presenta la matriz de correlaciones así como el análisis de varianza); Ajuste del modelo y Cambio en R cuadrado; en Coeficientes de regresión solicitaremos las Estimaciones; y en Residuos pediremos el estadístico de Durbin-Watson (figura 3).

5<sup>o</sup> paso: Como complemento al estadístico de Durbin-Watson podemos solicitar los gráficos Histograma y Gráfico de probabilidad normal (figura 4). Para acceder a este subcuadro de diálogo debemos cliquear en el botón de comando Gráficos situado en la parte inferior del cuadro de diálogo principal de regresión lineal.

La técnica de análisis de regresión múltiple, a diferencia del modelo de regresión simple, se encuentra muy generalizada en la investigación social. En este apartado presentamos la aplicación del modelo de regresión múltiple para la estimación del Producto Interior Bruto (P.I.B.).

## 6. Bibliografía Comentada

---

- Díaz-Agero, Coral (1999): “Indicadores sintéticos”, (en línea) <<http://www.festadisticas.fguam.es/indicadores/iae.html>> (consultado el 4 de abril de 2001).

*En este artículo la autora recoge el proceso que se sigue para convertir una batería de indicadores económicos representativos de la evolución de una macromagnitud en un índice compuesto o indicador sintético para a partir de éste realizar predicciones sobre la evolución de sus indicadores base. Dos cuestiones son las que hay que resolver: cómo se agregan los indicadores parciales y de qué forma participan cada uno de los indicadores parciales en la síntesis final. La autora agrega los indicadores parciales aplicando el procedimiento stepwise y cada uno de ellos participa ponderándose por sus respectivos coeficientes de correlación. De esta manera llega a concretar el indicador sintético cuantitativo del P.I.B.*

## 7. Resultados

---

Los resultados que se recogen en la salida de resultados son, en esencia, los mismos que ya hemos comentado en el capítulo dedicado al modelo de regresión lineal simple. Éstos los podemos agrupar en torno a los siguientes puntos.

- En primer lugar, el programa nos ofrece una serie de tablas que recogen información básica tanto del proceso como de las variables sometidas a análisis. Dentro de este primer grupo cabe destacar las tablas de descriptivos básicos y la de matriz de correlaciones.
- A continuación, se presenta una tabla (resumen del modelo) en la que se relaciona una serie de estadísticos

a partir de los cuáles valorar la bondad de ajuste de los datos del modelo. Con la misma finalidad se presenta la tabla de análisis de varianza.

- En tercer lugar, nos encontramos con la tabla en la que aparecen los coeficientes de la ecuación predictiva. Ésta se forma a partir de los coeficientes no estandarizados (B) cuando los valores de las dos variables tienen la misma escala. En el caso contrario deberemos elegir los coeficientes Beta.
- Por último, la exposición de resultados se cierra con una serie de representaciones gráficas cuya finalidad es facilitar el análisis del tipo de distribución de los residuales (gráfico de residuos tipificados y gráfico de probabilidad normal).

### 7.1. Estadísticos básicos

#### Estadísticos descriptivos

	Media	Desviación típ.	N
<b>actualmente</b>	4,79	2,14	1200
<b>hace 1 año</b>	4,91	2,13	1200
<b>dentro de 1 año</b>	5,67	3,10	1200

### 7.2. Matriz de Correlaciones Parciales

#### Correlaciones

		actualmente	hace 1 año	dentro de 1 año
<b>Correlación de Pearson</b>	<b>actualmente</b>	1,000	,871	,593
	<b>hace 1 año</b>	,871	1,000	,523
	<b>dentro de 1 año</b>	,593	,523	1,000
<b>Sig. (unilateral)</b>	<b>actualmente</b>	,	,000	,000
	<b>hace 1 año</b>	,000	,	,000
	<b>dentro de 1 año</b>	,000	,000	,
<b>N</b>	<b>actualmente</b>	1200	1200	1200
	<b>hace 1 año</b>	1200	1200	1200
	<b>dentro de 1 año</b>	1200	1200	1200

### 7.3. Resumen del proceso STEPWISE: relación y eliminación de variables

#### Variables introducidas/eliminadas

Modelo	Variables introducidas	Variables eliminadas	Método
1	hace 1 año	,	Por pasos (criterio: Probabilidad de F para entrar <= ,050, Probabilidad de F para salir >= ,100).
2	dentro de 1 año	,	Por pasos (criterio: Probabilidad de F para entrar <= ,050, Probabilidad de F para salir >= ,100).

a. Variable dependiente: actualmente

### 7.4. Estadísticos de Bondad de Ajuste

#### Resumen del modelo<sup>c</sup>

Modelo	R	R cuadrado	R cuadrado corregida	Error típ. de la estimación	Durbin-Watson
1	,871 <sup>a</sup>	,759	,759	1,05	
2	,886 <sup>b</sup>	,785	,785	,99	1,849

a. Variables predictoras: (Constante), P7B

### 7.5. Tabla de Análisis de Varianza

#### ANOVA<sup>c</sup>

Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	4148,999	1	4148,999	3773,649	,000 <sup>a</sup>
	Residual	1317,160	1198	1,099		
	Total	5466,159	1199			
2	Regresión	4292,078	2	2146,039	2187,932	,000 <sup>b</sup>
	Residual	1174,081	1197	,981		
	Total	5466,159	1199			

a. Variables predictoras: (Constante), hace 1 año

b. Variables predictoras: (Constante), hace 1 año, dentro de 1 año

c. Variable dependiente: actualmente

### 7.6. Estimaciones de parámetros o coeficientes de correlación: la ecuación de predicción

Coeficientes<sup>a</sup>

Modelo		Coeficientes no estandarizados		Coeficientes estandarizados		Sig.
		B	Error típ.	Beta	t	
1	(Constante)	,512	,076		6,738	,000
	hace 1 año	,872	,014	,871	61,430	,000
2	(Constante)	,259	,075		3,466	,001
	hace 1 año	,773	,016	,772	49,142	,000
	dentro de 1 año	,131	,011	,190	12,078	,000

<sup>a</sup>. Variable dependiente: actualmente

### 7.7. Variables excluidas del Modelo

Variables excluidas<sup>b</sup>


Modelo		Beta dentro	t	Sig.	Correlación parcial	Estadísticos de colinealidad
						Tolerancia
1	dentro de 1 año	,190 <sup>a</sup>	12,078	,000	,330	,727

<sup>a</sup>. Variables predictoras en el modelo: (Constante), hace 1 año

<sup>b</sup>. Variable dependiente: actualmente

### 7.8. Gráfico de distribución de residuales (gráfico 1)

Gráfico P-P normal de regresión Residuo tipificado



### Gráfico de probabilidad normal (gráfico 2)

Histograma

