

SEXO Y CIENCIA A LA SOMBRA DE PISA

Javier Balibrea Cárceles
José G. Clavel
Universidad Murcia

RESUMEN

La encuesta PISA está siendo analizada desde distintos puntos de vista y con una metodología similar. Los modelos multinivel parecen los más adecuados. Sin embargo, al margen del tratamiento que se le dé a los datos, casi todos los expertos coinciden en que trabajar con PISA es aceptar a priori las distintas “re-elaboraciones” de los datos llevadas a cabo por la OCDE y que hacen que alguno se pregunte dónde quedan las respuestas originales.

Precisamente por esto, pensamos interesante acudir a otra técnica, el análisis de ecuaciones estructurales, que ha sido ampliamente usado en psicología, Knight et al. (1996), y educación, Byrne y Shavelson (1987) o Cervelló et al. (2004), para medir conocimiento, inteligencia, motivación, etc. a partir de una batería de test. En concreto, en este trabajo, nos hemos centrado en las respuestas que dieron los estudiantes españoles en PISA 2006 y queremos medir las diferencias en el modo de aprender de hombres y mujeres.

Palabras clave: PISA 2006, modelo de ecuaciones estructurales, diferencias de género, conocimiento de ciencias.

1. INTRODUCCIÓN

Desde los primeros tiempos, la comparación entre sexos ha sido una constante. Desde el punto de vista de la educación, las diferencias entre el rendimiento, las capacidades y las actitudes de los niños y de las niñas son frecuente punto de atención. Así, es centro de debate si el rendimiento difiere de una educación mixta a otra diferenciada; si las capacidades verbales de las niñas son mayores que las de los niños; si los niños son más hábiles con las matemáticas que las niñas; etc. En el año 2000, apareció una nueva fuente de análisis: PISA. El *Programme for International Student Assessment* es una encuesta mundial a los niños de 15 años, centrada en aspectos verbales, matemáticos y científicos.

La literatura existente al respecto es, aunque cada vez más amplia, todavía escasa. Autores como Salomone (2003), Roirdan (1990,1984^a,2002), Mael (2005) o Marsh (1989, 1991) han analizado los rendimientos de las mujeres años después de graduarse, buscando diferencias en cuanto al tipo de centro en el que estudiaron (educación diferenciada vs. co-educación). Otros autores, como Lee y Bryck (1986, 1989), en su análisis del tipo de centro se centraron en otras características socio-económicas como la raza o la clase social. Un completo resumen, aunque sólo para EE.UU., en torno a la polémica de la educación diferenciada vs. co-educación es el documento 2005-01 de la Office of Planning, Evaluation and Policy Development del Departamento de Educación de EE.UU.

A nivel español, hay estudios, como el de Salas (2005), que afirman que es más fácil que un chico acabe una licenciatura que una chica o que ellas se decantan más por carreras de letras. Así mismo, Maestro (2006) cita en su estudio sobre los resultados de PISA 2003 que los chicos puntúan más en matemáticas en casi todos los países. Sin embargo, como queda patente, los estudios que analizan las diferencias de rendimiento, capacidades y actitudes entre sexos en materia de educación son muy escasos.

En este estudio, vamos a centrarnos en si existe o no una diferencia de rendimiento entre sexos en el campo de las ciencias. Para ello, utilizamos la tercera edición de la encuesta PISA, centrada en este ámbito y realizada en 2006. El modelo estadístico utilizado en el análisis

sis resulta algo novedoso para los estudios realizados con estos datos: Ecuaciones estructurales. Se trata de un modelo de regresión genérico en el que caben múltiples casos particulares de relaciones entre variables. Se tiene en cuenta la simultaneidad de las relaciones entre variables (regresión múltiple) y la existencia de variables latentes.

Son muchas las referencias sobre este tipo de análisis: desde el clásico Bollen (1989) hasta el socorrido Hair et al. (1995). Una buena revisión histórica es la de Bentler (1986). También en castellano empiezan a encontrarse trabajos que presentan esta metodología en respuesta a una demanda creciente, como, por ejemplo, Batista y Coenders (1999). Quizás donde quede más evidente el empuje y la implantación de estas técnicas sea en la web, que desde el principio albergó numerosos sites de encuentro. Uno de los más visitados es The Structural Equation Modeling Discussion Network, abierto como foro para este tipo de análisis desde 1993.

Estos modelos (a los que, en adelante, llamaremos SEM) permiten establecer relaciones entre variables observadas directamente y otras que, de algún modo sabemos que existen, pero no son expresamente medibles. Sería, por ejemplo, el caso de la calidad de un producto, la imagen de marca o en nuestro caso, la influencia del estatus familiar. Pues bien, los usuarios de SEM están más interesados en esas variables latentes -también llamadas constructos- que en las variables observadas que permiten medir las primeras. En efecto, a partir de las covarianzas o correlaciones entre las variables observadas, se pretende llegar a una explicación plausible (nada que ver con el “valor plausible” de PISA) del fenómeno estudiado. No es este el momento de explicar a fondo la técnica, pero nos gustaría destacar que SEM permite descomponer las covarianzas observadas, y no sólo las varianzas, dentro de una perspectiva de análisis conjunto. Por último, antes de entrar en el trabajo, hay que indicar que, como en muchas otras técnicas estadísticas, la popularización y el desarrollo de SEM han ido parejos a la implementación de un software específico cada vez más potente. Nosotros hemos empleado el paquete LISREL (Jöreskog y Sörbom), pero existen otros paquetes igualmente válidos y conocidos como AMOS (Arbuckle) o EQS (Bentler).

Siguiendo a Batista y Coenders (2000), el modelo de ecuaciones estructurales permite contemplar la globalidad del fenómeno analizado, teniendo en cuenta sus múltiples causas y las posibles relaciones entre variables. Además, facilita el tratamiento de la información puesto que reduce los nexos entre variables a una serie de factores explicativos, que nos ayudan a manejar con mayor facilidad el estudio. Por otra parte, la flexibilidad a la hora de plantear el modelo hace que el investigador analice su propio planteamiento. Es decir, el modelo estadístico se adapta al estudio y no al contrario, como sucede con otras formas de análisis. Por último, el modelo LISREL elimina el efecto del error de medida de los nexos entre variables. Admite que la realidad y la medición son diferentes.

2. LOS MODELOS

Emplearemos para las estimaciones los datos referentes a las respuestas de los estudiantes españoles en PISA 2006. Más adelante, cuando el modelo esté suficientemente estudiado, pensamos ampliar el estudio al resto de la muestra. De todas las preguntas del Cuestionario para el Estudiante (OCDE, 2007) vamos a emplear las siguientes:

- Para el MODELO 1: las variables son *Scie_Perf*, que es una medida de los cinco valores plausibles que PISA 2006 otorga a cada estudiante; *Interest*, elaborada como una combinación de las cuestiones ST21Q01 a STQ03. A mayor puntuación, menor interés por las ciencias; *Family*, una medida del nivel de estudio de los padres, establecida a partir de las preguntas ST06Q01 y ST09Q01. A mayor puntuación, menor nivel de estudios del padre y la madre; y, finalmente, la variable *Status*, construida a partir del ESCS (indicador del nivel socioeconómico del estudiante) y combinado con

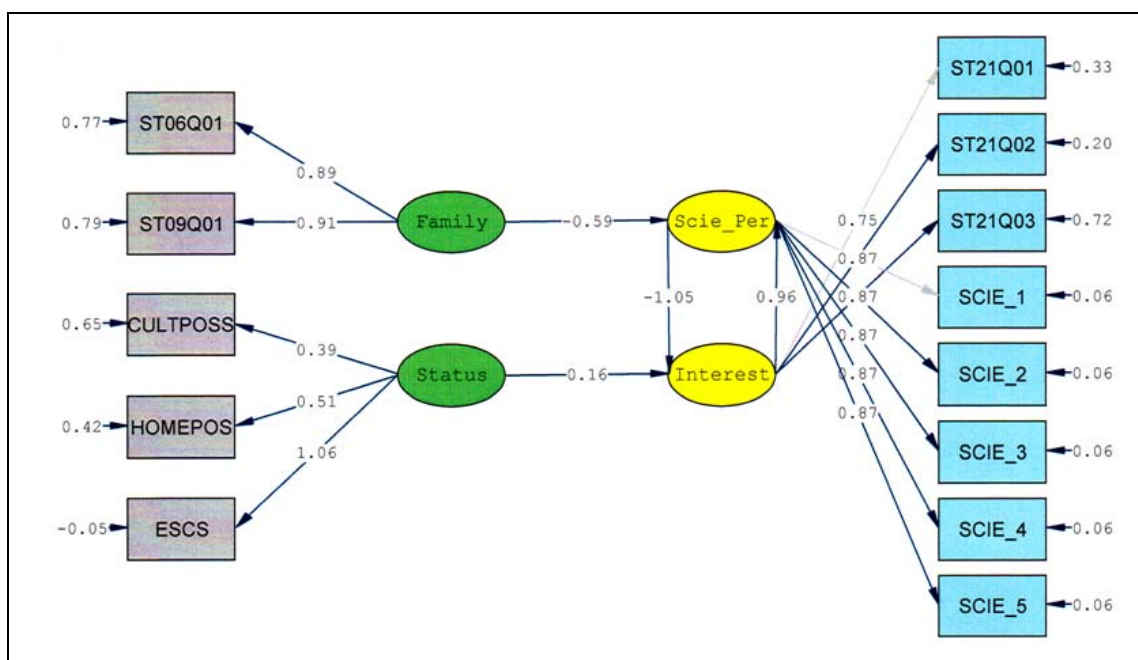
CULTPOSS (una medida de las posesiones “culturales” del alumno) y HOMEPOS (algo parecido a la anterior, pero referido a las posesiones “materiales” de la familia: TV, móviles, etc.).

- Para el MODELO 2, las variables son las mismas, con un nuevo parámetro a estimar: la relación directa entre la variable estatus y la puntuación alcanzada en Ciencias: Scie_Perf.
- Para el MODELO 3, introducimos una nueva variable, *Study*, obtenida a partir de las cuestiones ST31Q02 y ST31Q03, en las que se le preguntaba al alumno cuánto tiempo emplea a la semana en el estudio de las Ciencias. Los ítems están dispuestos de manera que a mayor puntuación, más tiempo de estudio del alumno.
- Finalmente, para el MODELO 4, empleamos una variable latente, *SelfC*, con la que pretendemos medir la confianza que tiene el alumno en sí mismo. Para ello, empleamos de la ST37Q01 a la ST37Q04 del cuestionario del alumno. Estas cuestiones están planteadas de manera que a mayor puntuación, menor es la confianza del estudiante en superar las Ciencias.

3. LAS ESTIMACIONES

Las estimaciones han sido realizadas para ambos grupos, hombres y mujeres, y para el total de la muestra. El MODELO 1 ha quedado de la siguiente manera para los hombres:

Gráfico 1. Estimaciones relativas al MODELO 1 para hombres



El conjunto de las estimaciones sería:

$$\text{Scie_Per} = 0.96 \cdot \text{Interest} - 0.59 \cdot \text{Family}, \text{Errorvar.} = 2.25,$$

(0.28)	(0.065)	(0.66)
3.46	-9.05	3.42

$$\text{Interest} = -1.05 \cdot \text{Scie_Per} + 0.16 \cdot \text{Status}, \text{Errorvar.} = 1.37,$$

(0.17)	(0.056)	(0.22)
-6.35	2.85	6.23

Como se observa, todos los coeficientes son significativamente distintos de cero (entre paréntesis la desviación estándar y debajo el valor del estadístico t, para la hipótesis nula de nulidad del parámetro).

Para las mujeres, ese mismo modelo es:

$$\text{Scie_Per} = 0.37 * \text{Interest} - 0.45 * \text{Family}, \text{Errorvar.} = 1.18,$$

(0.18)	(0.033)	(0.22)
2.11	-13.49	5.37

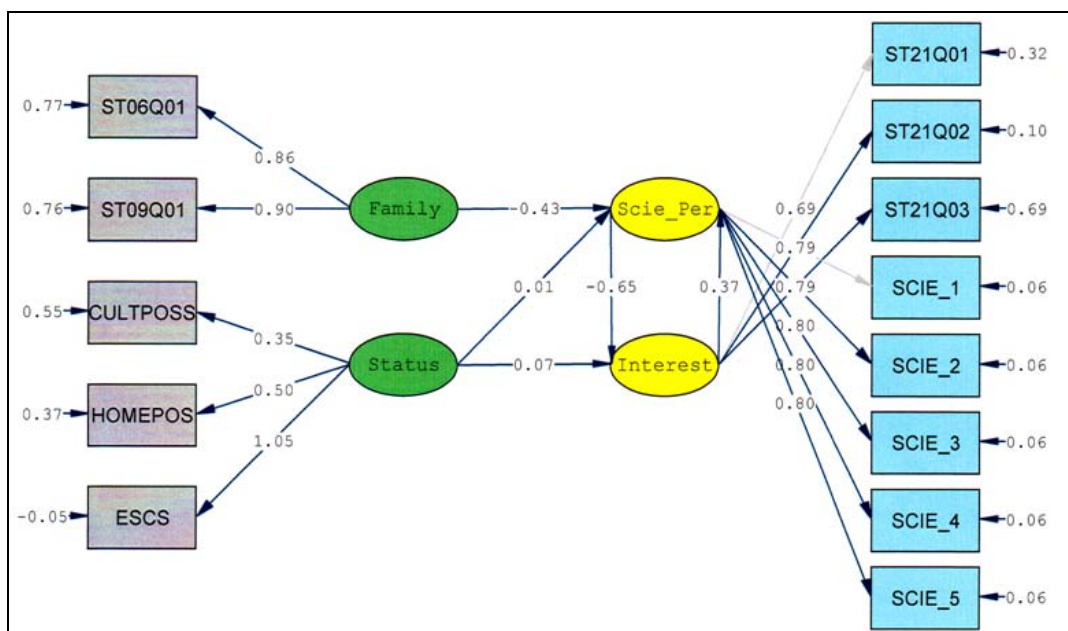
$$\text{Interest} = -0.65 * \text{Scie_Per} + 0.072 * \text{Status}, \text{Errorvar.} = 0.99,$$

(0.14)	(0.051)	(0.090)
-4.50	1.40	11.02

Como se puede ver, la importancia del factor familia sigue siendo negativa: como se esperaba, a mayor puntuación, es decir, peor cualificación de los padres, menor será la calificación obtenida en Ciencias (*Scie_Per*). Sin embargo, para las mujeres, el peso es menor: -0.45 frente -0.59, que era la estimación para los hombres.

Por otro lado, el interés influye más en los hombres (0.96) que en las mujeres (0.37). También es interesante comprobar que ese interés está más vinculado al estatus familiar en el caso de los hombres (0.16), que en el de las mujeres (0.072) y que ambos son significativos. Este dato nos lleva a plantear el MODELO 2, que parte de las mismas variables, pero establece una nueva relación directa: la del estatus con la calificación obtenida en Ciencias. En concreto el modelo, estimado para las mujeres queda:

Gráfico 2. Estimaciones relativas al MODELO 2 para mujeres



La ecuación estimada para la variable *Scie_Per* es:

$$\text{Scie_Per} = 0.37 * \text{Interest} - 0.43 * \text{Family} + 0.011 * \text{Status}, \text{Errorvar.} = 1.18,$$

(0.18)	(0.074)	(0.058)	(0.23)
2.00	-5.82	0.19	5.22

Es decir, que, como se esperaba, el estatus social influye directamente y no sólo por medio de la variable interés, tal y como se había planteado en el MODELO 1. Para comparar con los resultados obtenidos para el grupo de los hombres, volvemos a estimar el modelo y ahora obtenemos la siguiente ecuación:

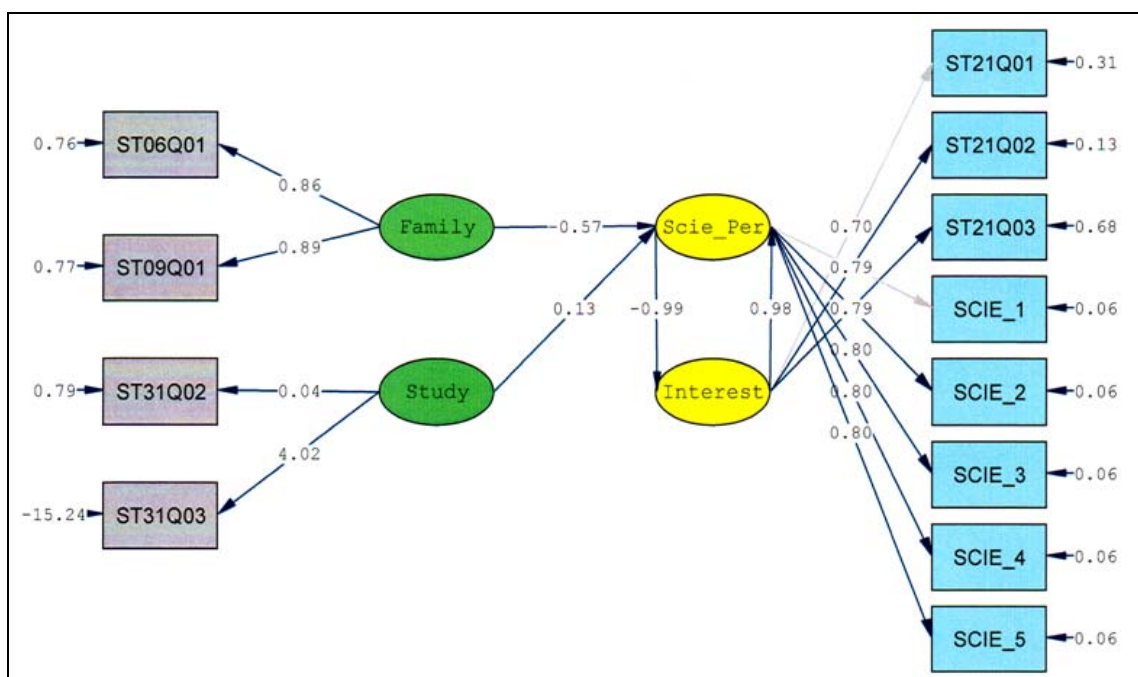
$$\text{Scie_Per} = 0.69 * \text{Interest} - 0.39 * \text{Family} + 0.13 * \text{Status}, \text{Errorvar.} = 1.69,$$

(0.29)	(0.086)	(0.052)	(0.53)
2.42	-4.55	2.44	3.21

Vemos que el *Status* sigue influyendo en los hombres más que en las mujeres. Por otra parte, cuando se le permite al modelo estimar la influencia directa sobre *Scie_Per*, observamos que cae la influencia de la variable *Family*, que recoge el nivel de estudio de los padres. Esto ocurre, sobre todo, en el caso de los hombres.

En el MODELO 3, introducimos la variable *Study* que, como ya hemos dicho, recoge el tiempo dedica por estudiante a las asignatura de ciencias. El modelo, una vez estimado para las mujeres de la muestra quedaría representado por el siguiente gráfico:

Gráfico 3. Estimaciones relativas al MODELO 3 para mujeres



Para los hombres, el modelo estimado queda:

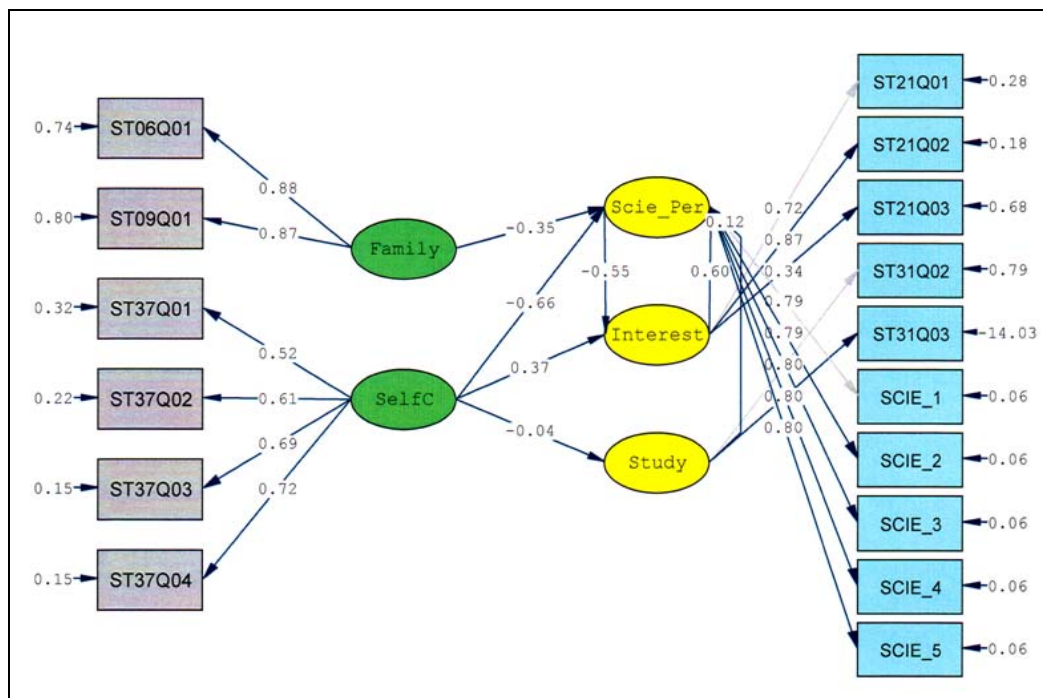
$$\text{Scie_Per} = 1.03 * \text{Interest} - 0.58 * \text{Family} - 0.12 * \text{Study}, \text{Errorvar.} = 2.41,$$

(0.069)	(0.030)	(0.0061)	(0.17)
14.96	-19.67	-19.82	14.45

Lo que más nos ha llamado la atención es el cambio de signo del coeficiente que mide la influencia del estudio. La interpretación es que las mujeres, cuanto más tiempo dedican a su estudio, menor calificación obtienen en las pruebas de Ciencias, mientras que los hombres es justo al revés: cuanto menos estudien, mejor. Esto plantea un modelo pedagógico curioso. Quizás la explicación puede estar en que, aquellos alumnos que dominan la materia no necesitan dedicar demasiado tiempo... ¡pero lo mismo debería ocurrir con las mujeres!

En cualquier caso, como se trata de tratar de intentar encajar en el modelo las percepciones de cada estudiante, hemos planteado un MODELO 4, en el que recogemos esto a través de la variable *SelfC*, que mide la facilidad del estudiante para abordar problemas y conceptos relacionados con las Ciencias. Por ejemplo, una de las formulaciones a las que deben responder si están o no de acuerdo es: “Aprender temas avanzados relacionados con la ciencia me es fácil”. Las respuestas posibles son: muy de acuerdo (1) a muy en desacuerdo (4). El modelo, estimado una vez más para el grupo de las mujeres, queda:

Gráfico 4. Estimaciones relativas al MODELO 4 para mujeres



Como se puede observar, el *Study* sigue influyendo positivamente, como es de esperar, en la calificación que se obtiene en Ciencias. Igualmente, como parece lógico, cuanto mayor es la facilidad de la alumna para las Ciencias (es decir, menor valor toma la variable *SelfC*) más tiempo dedica al estudio, por que estudia lo que le gusta, y mejor calificación global en Ciencias.

Las dos ecuaciones a las que hemos hecho referencia, para el caso de los hombres quedan:

$$\begin{aligned} \text{Scie_Per} &= 0.72 * \text{Interest} + 0.12 * \text{Study} - 0.33 * \text{Family} - 0.70 * \text{SelfC}, \\ \text{Study} &= -0.031 * \text{SelfC}, \end{aligned}$$

Y se observa que la “anomalía pedagógica” derivada de la interpretación del coeficiente que relacionaba el rendimiento en Ciencias y el tiempo dedicado al estudio desaparece: tanto en hombres como en mujeres, cuanto más tiempo se dedique al estudio, más alta será la calificación global en Ciencias. El resto de parámetros tienen los signos esperados, aunque las magnitudes varían entre un grupo y otro.

4. CONCLUSIONES

Los modelos de Ecuaciones Estructurales resultan útiles para analizar la información derivada de test y otras formas de encuesta como PISA. Permiten flexibilidad de modelos de estudio y han sido ampliamente contrastados por psicólogos y estudiosos de los rendimientos educativos. Por otra parte, los resultados obtenidos han sido consistentes con los hallazgos de otros investigadores que han empleado métodos diferentes.

En lo que hace referencia al tema abordado en el trabajo, la diferenciación entre hombres y mujeres, ha quedado, claramente, puesta de manifiesto. En próximos trabajos incluiremos nuevas cuestiones que han sido también tratadas por PISA, pero que han quedado fuera: preocupación medioambiental, tipo de enseñanza, nota obtenida en otras materias (matemáticas y lectura), etc. Desde el punto de vista del modelo, incluiremos los contrastes de igualdad de parámetros, los modelos para distintas muestras, así como la introducción de variables cualitativas y no solo cuantitativas.

5. REFERENCIAS BIBLIOGRÁFICAS

- BATISTA, J.M y COENDERS, G. (2000). “Modelos de Ecuaciones Estructurales”. *Cuadernos de Estadística* 6.1.
- BENTLER, P.M. (1986). “Structural equation modeling and Psychometrika: An historical perspective on growth and achievements”. *Psychometrika*, 31, pp. 35-51
- BYRNE, B.M. y SHAVELSON, R.J. (1987). “Adolescent self-concept: Testing the assumption of equivalent structure across gender”. *American Educational Research Journal*, 24, pp.365-385.
- BOLLEN, K. A. (1989). *Structural Equations with Latent Variables*, J. Wiley & Sons, Toronto.
- CALERO, J. y ESCORDIBUL, J. O. (2007). “Evaluación de servicios educativos: el rendimiento en los centros públicos y privados medido en PISA 2003”. *Hacienda Pública Española/Revista de Economía Pública*, 183-(4/2007), pp.33-66.
- CERVELLÓ, E. et al. (2004). “Aplicación de modelos estructurales al estudio de la motivación de los alumnos en las clases de Educación Física”. *Revista de Educación*, 335, pp. 371-382.
- DU TOIT, M. y DU TOIT, S. (2001) *Interactive LISREL: User's Guide*. SSI.
- HAIR, J.F., ANDERSON, R.E.; TATHAM, R.L. y BLACK, W.C. (1995). *Multivariate Data Analysis with Readings* (4th ed), Prentice Hall, New Jersey.
- ISEI-IVEI Instituto Vasco de Evaluación e Investigación Educativa (2007). *Primer informe de Evaluación PISA 2006*.
- JÖRESKOG, K. y SÖRBOM, D. (1996). *LISREL 8: User's Reference Guide*. SSI.
- KNIGHT, G. P; FABES, R. A; y HIGGINS, D. A. (1996). “Concerns about drawing causal inferences from meta-analyses: An example in the study of gender differences in aggression”. *Psychological Bulletin*, 119, pp. 410-421.
- MAESTRO, C. (2006). “La evaluación del sistema educativo”. *Revista de Educación*, extraordinario 2006, pp. 315-336.
- OECD (2007). *Student Questionnaire for PISA 2006*. Paris.
- RIORDAN, C. (2007). *The Effects of Single Sex Schools: What Do We Know?* Presentation at the Congress on Single Sex Schools. Barcelona.
- SALAS, M. (2005). La demanda de educación superior: un análisis microeconómico con datos de corte transversal. *Revista de Educación*, 337, pp. 327-349.
- SALINAS, J. y SANTÍN, D. (2007). “El efecto de la inmigración en los resultados del sistema educativo. Una aproximación a partir de PISA 20032. *XVI Jornadas Asociación de Economía de la Educación*.