

PISA 2022. Predictores del rendimiento en pensamiento computacional en Educación Secundaria en España

PISA 2022. Predictors of computational thinking performance in secondary education in Spain

Pablo Javier Ortega-Rodríguez
Universidad Autónoma de Madrid. Madrid, España.
pabloj.ortega@educuam.es

Resumen

Este estudio pretende conocer el efecto de un conjunto de predictores sobre el rendimiento en pensamiento computacional. La muestra está formada por 30800 estudiantes españoles de Educación Secundaria que han participado en PISA 2022: 15561 chicos (50.5%) y 15239 chicas (49.5%), procedentes de 966 centros educativos. Se ha utilizado una regresión múltiple multinivel, que ha permitido analizar los efectos significativos de las variables independientes sobre el rendimiento a dos niveles (Estudiante y Centro). Los resultados muestran que los chicos obtienen más puntos en el rendimiento en pensamiento computacional que las chicas, pues existe una brecha de género en la competencia digital a favor de ellos. El contexto socioeconómico del alumnado y el uso de las TIC en casa tienen un gran impacto sobre el rendimiento. A nivel de centro, los resultados muestran que los centros privados y con mayor disponibilidad de recursos TIC obtienen más puntos que los centros públicos con menos recursos. Estos resultados sugieren la necesidad de promover programas sobre pensamiento computacional en los centros educativos para fomentar la vocación de los estudiantes en las disciplinas STEM, utilizar aplicaciones para desarrollar el pensamiento computacional y reforzar la competencia digital del alumnado.

Palabras clave: competencia digital, brecha de género, pensamiento computacional, rendimiento escolar, Tecnologías de la Información y la Comunicación (TIC).

Abstract

This study aims to determine the effect of a set of predictors on performance in computational thinking. The sample consists of 30800 Spanish secondary students who participated in PISA 2022: 15561 boys (50.5%) and 15239 girls (49.5%), from 966 schools. A multilevel multiple regression was used to analyse the significant effects of the independent variables on performance at two levels (Students and Schools). The results show that boys score more points in computational thinking performance than girls, as there is a gender gap in digital competence in favour of boys. The socio-economic background of the students and the use of ICT at home have a strong impact on performance. At school level, the results show that private schools with greater availability of ICT resources score more points than public schools with fewer resources. These findings suggest the need to promote computational thinking programmes in schools to foster students' vocation in STEM disciplines, to use applications to develop computational thinking and to reinforce students' digital competence.

Key words: digital competence, gender differences, computational thinking, academic achievement, ICT.

1. Introducción

En los últimos años, la adquisición de nociones sobre pensamiento computacional ha cobrado relevancia en el ámbito educativo, en tanto que permite el desarrollo de habilidades para resolver problemas, utilizando las nuevas tecnologías (García-Peñalvo & Mendes, 2018, Picado-Arce et al., 2021). En este sentido, es necesario repensar las formas en las que se plantea la formación de la ciudadanía para alcanzar un desarrollo competencial de acuerdo con la Sociedad del Conocimiento (Cabero-Almenara & Palacios-Rodríguez, 2020).

En los años 80, Seymour Papert, uno de los creadores del lenguaje de programación denominado Logo, creó un robot tortuga o “animal cibernético” controlado por el ordenador, siendo Logo el lenguaje en el que se realizaba la comunicación con la tortuga, con el fin de que los niños pudieran moverla mediante instrucciones simples: adelante, atrás, izquierda y derecha (Papert, 1980, p.11). Wing (2006) define el pensamiento computacional como la habilidad para resolver problemas, diseñar sistemas y comprender el comportamiento humano, basándose en los conceptos básicos de la informática.

La Sociedad Internacional de Tecnología en Educación (*International Society for Technology in Education*, ISTE, 2023, p. 7) define el pensamiento computacional como un proceso de resolución de problemas, que incluye las siguientes seis características: 1. Formular problemas de una manera que permita utilizar un ordenador y otras herramientas para resolver un problema, 2. Organizar y analizar datos de manera lógica, 3. Representar datos a través de abstracciones, como modelos y simulaciones., 4. Automatizar soluciones mediante el pensamiento algorítmico (mediante una serie de pasos ordenados), 5. Identificar, analizar e implementar posibles soluciones con el objetivo de lograr la combinación más eficiente y efectiva de pasos y recursos, y 6. Generalizar y transferir este proceso de resolución de problemas a una amplia variedad de situaciones. Para Fraillon et al. (2019, p. 7) es una forma de resolución de problemas en la que las soluciones se pueden establecer e implementar de forma procedimental (paso a paso) con un ordenador, esto es, la capacidad de pensar con el ordenador como una herramienta de trabajo (Berland & Wilensky, 2015, p. 630).

Los factores en los que se encuentran diferencias significativas de rendimiento en el pensamiento computacional son: el género, el contexto socioeconómico, la competencia digital, el uso de las Tecnologías de la Información y la Comunicación (TIC) en tareas de codificación, la disponibilidad y el uso de las TIC en casa, la disponibilidad de las TIC en el centro, la titularidad y el área del centro.

En cuanto al primer factor del estudiante, el sexo, la investigación ha demostrado diferencias de género en el nivel de pensamiento computacional (Villalustre, 2024). El estudio de Tsai et al. (2019) demostró que los chicos adquieren puntuaciones más altas en pensamiento computacional que las chicas, en tanto que ellos muestran más confianza que ellas en el desarrollo de algoritmos (construir procedimientos para un programa) y en la depuración de programas (localizar errores en un programa y corregirlos). En este sentido, el trabajo de Román González et al. (2018), que tuvo como objetivo conocer el nivel de pensamiento computacional de 1251 estudiantes de Educación Secundaria en España, también demostró mayor nivel de pensamiento computacional en ellos. El estudio de Guggemos (2021) demostró que el sexo predice el nivel de pensamiento computacional en educación secundaria y que la brecha de género, en esta etapa, se debe al bajo nivel de autoeficacia digital de las chicas (Polat et al., 2021). Asimismo, el trabajo de Chan et al. (2021) analizó las habilidades sobre

pensamiento computacional de 153 estudiantes de educación secundaria. Los resultados mostraron que los chicos alcanzaron un nivel alto y las chicas, un nivel moderado, en tanto que ellas presentaron más ansiedad y falta de confianza en el uso del lenguaje de programación. Otros estudios (Herrero-Álvarez et al., 2023; Uslu, 2023) no encontraron diferencias significativas en función del sexo.

Respecto al segundo factor del estudiante, el Índice Social, Económico y Cultural (ISEC), la investigación ha demostrado su influencia sobre el rendimiento académico del alumnado (Coleman et al., 1966; Lee & Borgonovi, 2022; Walkington et al., 2018), de modo que es un predictor del rendimiento en Matemáticas (López et al., 2023), que incluye otras habilidades del área, como el pensamiento computacional (Hann, 2020). El estudio de Pivovarova & Powers (2019) analizó el efecto de los factores del alumnado y escolares sobre una muestra de 3,700 alumnos estadounidenses en la edición de 2012 del Programa para la Evaluación Internacional de los Estudiantes (PISA, *Programme for International Student Assessment*). Los resultados mostraron diferencias significativas a favor del alumnado procedente de un contexto favorecido. En esta línea, el trabajo de Kang & Cogan (2022), que trabajó con la muestra de Rusia en el estudio PISA del mismo año, demostró que los estudiantes de contextos desfavorecidos tenían dificultades para aplicar y transferir sus conocimientos y habilidades matemáticas a la resolución de problemas.

En lo que concierne al tercer factor del estudiante, la competencia digital del alumnado, puede definirse como el conjunto de los conocimientos, las habilidades y las actitudes necesarios para el uso seguro de la tecnología en diversas situaciones (Restrepo-Palacio & Segovia, 2020). La investigación ha demostrado su impacto en la motivación hacia el aprendizaje de conceptos sobre pensamiento computacional (Liao et al., 2022; Moreira-Fontán et al., 2019), de modo que existe una correlación entre la competencia digital y el nivel de pensamiento computacional (Jun et al., 2017; Wei et al., 2021). Otros estudios han demostrado diferencias de género, a favor de los chicos en la competencia digital (Lucas et al., 2022; Niño-Cortés et al., 2023), debido a que ellos presentan una actitud más favorable hacia las tecnologías que ellas.

Respecto al cuarto factor del estudiante, el uso de las TIC para realizar actividades sobre pensamiento computacional (codificación o algoritmo), diferentes estudios han puesto de relieve la necesidad de profundizar en la relación entre la competencia digital y el pensamiento computacional (Adell et al., 2019; Hsu et al., 2019). La investigación ha demostrado la correlación entre el nivel de uso de las TIC con fines académicos y el nivel de pensamiento computacional del alumnado (Esteve-Mon et al., 2020), que pone de relieve la relación entre la competencia digital para resolver problemas y el pensamiento computacional (Caballero-González & García-Valcárcel, 2020; Juskeviciene & Dagiene, 2018; Loureiro et al., 2022; Rodríguez-Martínez et al., 2020).

En lo tocante al quinto factor del estudiante, la disponibilidad y el uso de las TIC en casa, la investigación ha demostrado que la posesión de recursos disponibles en el hogar de cada estudiante incide sobre el rendimiento (Sayans-Jiménez et al., 2018; Lopes et al., 2022), pues permiten que el alumnado refuerce la alfabetización digital de la escuela (Chang, 2023). En este sentido, el acceso a las TIC en casa depende del contexto socioeconómico del alumnado (González-Betancor et al., 2021; Gubbels et al., 2020).

Con respecto al primer factor escolar, la disponibilidad de recursos TIC en la escuela, la investigación ha demostrado su influencia en el rendimiento en la edición de PISA 2012 (Escardíbul & Mediavilla, 2016) y que la diferencia de rendimiento se debe a la dotación de recursos de la escuela (Quiroz et al., 2018), en tanto que el acceso a

recursos digitales favorece la adquisición de nociones sobre pensamiento computacional del alumnado, como el manejo de algoritmos (Lee et al., 2023).

En cuanto al segundo factor escolar, la titularidad del centro educativo, la investigación ha demostrado un mayor nivel de pensamiento computacional en los centros privados que en los públicos (Sun et al., 2023), pues las escuelas privadas ofrecen experiencias de enseñanza de pensamiento computacional en mayor medida que las escuelas públicas (Martínez & Echeveste, 2015). En este sentido, también se aprecian diferencias en el rendimiento en el tercer factor escolar, el área donde se localiza el centro, a favor de las zonas urbanas y en detrimento del área rural (Kale et al., 2018), mientras que otros estudios no encontraron diferencias significativas en función de la ubicación (Aguayo-Téllez & Martínez-Rodríguez, 2020).

Esta fundamentación teórica sugiere la necesidad de avanzar en el conocimiento sobre la influencia de los determinantes del alumnado y de la escuela sobre el rendimiento en pensamiento computacional en educación secundaria, pues en la actualidad, los países enfrentan nuevos retos en todas las áreas de la vida, que provienen de la rápida propagación de los ordenadores y dispositivos, tales como robots y teléfonos inteligentes, y que precisan de habilidades de pensamiento computacional (Ministerio de Educación, Formación Profesional y Deportes, 2023a, p. 5).

El Marco para las pruebas de Matemáticas de PISA 2022 define el pensamiento computacional como un constructo o “conjunto de habilidades que incluyen el reconocimiento de patrones, el diseño y el uso de abstracciones, la descomposición de patrones, determinar qué herramientas de cálculo pueden ser empleadas para analizar problemas, y definir algoritmos como parte de una solución” (Ministerio de Educación, Formación Profesional y Deportes, 2023a, p. 7).

El objetivo de esta investigación es conocer el efecto de un conjunto de predictores del rendimiento en pensamiento computacional en los estudiantes españoles que han participado en PISA 2022.

2. Método

Este estudio se enmarca en un diseño de investigación no experimental, pues no es posible manipular las variables ni asignar de forma aleatoria a los participantes o el tratamiento. Se trata de un estudio *ex post facto*, pues no se pueden manipular las variables independientes, de modo que el fenómeno es analizado una vez que ya ha ocurrido (Kerlinger & Lee, 2002).

Participantes

La población objeto de estudio de PISA está formada por estudiantes con una edad de entre 15 años y 3 meses y 16 años y 2 meses, que pueden estar matriculados en cualquier programa, ya sea la Educación Secundaria Obligatoria (ESO) o Formación Profesional (FP), en más de 80 países (Ministerio de Educación, Formación Profesional y Deportes, 2023b, p.15). La muestra participante en España está formada por 30800 estudiantes, 15561 chicos (50.5%) y 15239 chicas (49.5%), correspondientes a 966 centros educativos.

Tabla 1

Medidas de centralización y dispersión por Comunidad Autónoma / Ciudad autónoma

Comunidad Autónoma / Ciudad autónoma	N	Centros	Media	Desviación Típica
Andalucía	1707	53	465.42	84.93
Aragón	1420	45	495.36	84.95
Asturias	1724	53	506.21	85.30
Cantabria	1677	52	504.92	82.21
Castilla-La Mancha	1671	53	469.63	78.22
Castilla y León	1733	55	506.31	82.25
Cataluña	1597	51	473.79	91.92
Extremadura	1685	54	477.66	83.55
Galicia	1824	58	495.84	80.19
Islas Baleares	1576	53	473.60	83.36
Islas Canarias	1686	54	457.63	80.4
La Rioja	1394	47	494.06	85.71
Madrid	2138	62	503.8	85.54
Murcia	1669	52	474.96	85.07
Navarra	1826	53	499.6	84.45
País Vasco	3244	96	491.55	83.41
Valencia	1625	53	481.46	84.04
Ceuta	345	12	420.04	80.52
Melilla	259	10	421.28	86.23
España	30800	966	485.88	85.62

Fuente: Elaboración propia

Instrumentos

Esta investigación incluye variables tomadas de los siguientes instrumentos del Estudio PISA 2022 en España:

-Cuestionario del alumnado. Incluye preguntas sobre el sexo, el estatus socioeconómico y cultural, la familia, la casa, la opinión de los estudiantes sobre el centro educativo, el horario y el tiempo de clase.

-Cuestionario de familiaridad del alumnado con las TIC. Recoge información sobre los recursos digitales que utiliza el alumnado dentro y fuera de la clase. Los recursos digitales hacen referencia a dispositivos digitales o hardware (p. ej., ordenadores, tabletas, smartphones e impresoras 3D), software (p. ej., programas, aplicaciones y herramientas de comunicación) y recursos en línea (p. ej., páginas web).

-Cuestionario de los centros educativos. Cumplimentado por los directores, incluye preguntas sobre las CCAA, el contexto escolar del centro, la dirección, el profesorado, la evaluación, los grupos específicos y el clima escolar.

VARIABLES Y PROCEDIMIENTO DE ANÁLISIS

Esta investigación utiliza modelos jerárquicos lineales, que permiten conocer los efectos de las variables independientes sobre la variable dependiente en dos niveles (Estudiante y Centro).

Las puntuaciones de los alumnos se obtienen a partir de la aplicación del modelo de Rasch y se informan mediante escalas, con una puntuación media de 500 y desviación estándar de 100 entre los países de la Organización para la Cooperación y el Desarrollo Económicos (OCDE; *Organisation for Economic Co-operation and Development*, OECD, 2023). Las variables de respuesta son los valores plausibles que PISA asigna a cada alumno en la prueba de pensamiento computacional, incluida en la competencia matemática.

Para calcular la variable dependiente (el rendimiento en pensamiento computacional), se han efectuado estimaciones independientes para cada valor plausible y se ha calculado la media de los parámetros (Wu & Adams, 2002). En las pruebas de pensamiento computacional, se trabaja con modelos no definidos que precisan de un enfoque de pensamiento computacional para llegar a la solución de problemas, incluyendo estrategias que requieren de una toma secuencial de decisiones, el trabajo con simulaciones por ordenador o una flexibilidad en la comprensión de conceptos familiares (Ministerio de Educación, Formación Profesional y Deportes, 2023b, p. 20). El informe PISA establece seis niveles de rendimiento: Nivel 1 (0-419 puntos), nivel 2 (420-481), nivel 3 (482-544), nivel 4 (545-606), nivel 5 (607-668) y nivel 6 (a partir de 669). La puntuación media del alumnado en pensamiento computacional es de 485.88 puntos (Chicos = 489.71; Chicas = 481.98).

En el primer nivel (Estudiante), se han introducido las siguientes covariables explicativas:

Tabla 2
Predictores del nivel 1 (Estudiante)

Variable	Media/Moda	D.T.	Mínimo	Máximo
Género	0	0.5	0	1
Contexto socioeconómico del alumnado	0	1	-5,81	2.51
Competencia digital del alumnado	1.92	0.78	0	4
Uso de las TIC para realizar actividades de pensamiento computacional	1.34	0.85	0	4
Disponibilidad y uso de las TIC en casa	5.72	.856	0	5

Fuente: Elaboración propia.

-Género: Variable dummy (0=Chico, 1=Chica). *Cuestionario del alumnado*.

-Contexto socioeconómico del alumnado (*Estatus Socioeconómico y Cultural, ESC*): es una puntuación formada por tres componentes: el nivel educativo más alto de los padres (índice PARED), el estatus ocupacional más alto de los padres (índice HISEI) y las posesiones del hogar (índice HOMEPOS, que es un indicador de la riqueza familiar). Se presenta tipificada para facilitar su interpretación (Ministerio de Educación y Formación Profesional, 2023b, p. 118). *Cuestionario del alumnado*.

-Competencia digital: Informa sobre la capacidad del alumnado para realizar una serie de tareas cuando utiliza recursos digitales (0=No puedo hacerlo, 1=Me cuesta trabajo hacerlo yo solo, 2=Puedo hacerlo con un poco de esfuerzo, 3=Puedo hacerlo fácilmente, 4=No sé qué es esto). *Cuestionario de familiaridad del alumnado con las TIC*.

Índice creado a partir de las siguientes variables:

- Buscar y encontrar en Internet información importante.
- Evaluar la calidad de la información que encuentre en Internet.
- Compartir información práctica con un grupo de alumnos.
- Colaborar con otros alumnos en un trabajo en grupo.
- Explicar a otros alumnos cómo compartir contenido digital en línea o en una plataforma escolar.
- Escribir o editar texto para un trabajo de clase.
- Recopilar y registrar datos (p. ej., mediante registradores de datos, Microsoft® Access™, Google® Forms, hojas de cálculo).
- Crear una presentación multimedia (con sonido, imágenes o vídeo).
- Crear, actualizar y mantener una página web o un blog.
- Cambiar la configuración de un dispositivo o aplicación para proteger mis datos y mi privacidad.
- Seleccionar el programa o aplicación más eficiente que me permita llevar a cabo una tarea específica.
- Crear un programa de ordenador (p. ej., en Scratch®, Python®, Java®).
- Identificar el origen de un error en un programa después de tener en cuenta una lista de causas potenciales.
- Descomponer un problema y representar una solución en una serie de pasos lógicos, como un algoritmo.

-Uso de las TIC para realizar actividades de pensamiento computacional (codificación o algoritmo): Informa sobre la frecuencia con la que el alumnado usa recursos digitales al hacer estas actividades (0=Nunca o casi nunca, 1= Una o dos veces al año, 2=Una o dos veces al mes; 3=Una o dos veces a la semana; 4=Todos o casi todos los días).

-Disponibilidad y uso de las TIC en casa. Índice creado a partir de la frecuencia con la que el alumnado utiliza los siguientes recursos digitales en casa (0=Nunca o casi nunca, 1= Una o dos veces al mes, 2=Una o dos veces a la semana; 3=Todos o casi todos los días, 4=Varias veces al día; 5=No tengo acceso a este recurso fuera de clase).

Frecuencia con la que usa los siguientes recursos en casa:

- Un ordenador de sobremesa o un portátil.
- Un smartphone (es decir, un móvil con acceso a Internet).
- Tabletas.
- Juegos, aplicaciones o programas de ordenador educativos, y otras herramientas de aprendizaje.
- Videojuegos o juegos en línea.

Cuestionario de familiaridad del alumnado con las TIC.

En el segundo nivel (Centro), se han introducido las siguientes variables:

Tabla 3

Predictores del nivel 2 (Centro)

Variable	Media/Moda	D.T.	Mínimo	Máximo
Disponibilidad de TIC en el centro	1.86	1.09	0	3
Titularidad del centro	0	0.37	0	1
Área donde se localiza el centro	2	1.99	0	5

Fuente: Elaboración propia.

-Disponibilidad de TIC en el centro. Índice creado a partir del grado de acuerdo/desacuerdo del alumnado con las siguientes afirmaciones (0=Totalmente en desacuerdo, 1=En desacuerdo, 2=De acuerdo, 3=Totalmente de acuerdo):

- Hay suficientes recursos digitales para todos los alumnos de mi centro.
- Hay suficientes dispositivos digitales con acceso a Internet en mi centro.
- La velocidad de Internet del centro es suficiente.
- Los recursos digitales de mi centro funcionan adecuadamente.
- Los recursos digitales dentro del aula son de fácil acceso.
- Los recursos digitales de aprendizaje disponibles en mi centro hacen el aprendizaje interesante.
- El centro proporciona apoyo técnico suficiente para ayudar a los alumnos a utilizar los recursos digitales.
- Los profesores de mi centro tienen las habilidades necesarias para usar dispositivos digitales durante las clases.
- Los profesores de mi centro están dispuestos a utilizar recursos digitales para la enseñanza.

Cuestionario de familiaridad del alumnado con las TIC.

- Titularidad del centro: (0=Público, 1=Privado). *Cuestionario de los centros educativos.*
- Área donde se localiza el centro: 0=Un área rural (menos de 3 000 personas); 1= Un pueblo pequeño (de 3.000 a aproximadamente 15.000 habitantes); 2= Un pueblo (de 15.000 a unas 100.000 personas); 3=Una ciudad (de 100.000 a aproximadamente 1.000.000 de habitantes); 4=Una ciudad grande (de 1.000.000 a aproximadamente 10.000.000 de habitantes); 5= Una megaciudad (con más de 10.000.000 de habitantes).

Los análisis se realizaron con el programa MLwiN 2.36 y se calcularon las estimaciones mediante el procedimiento de Mínimos Cuadrados Interactivos Generalizados (*Iterative Generalized Least Squares - IGLS*) (Goldstein, 2003).

3. Resultados

El proceso de modelización empieza con la formulación del modelo nulo, que no incluye variables predictoras y no tiene capacidad explicativa alguna, pero resulta fundamental por dos razones: establece la base para compararlo con el modelo definitivo e informa de la varianza inicial en los dos niveles (Tourón et al., 2023).

El modelo nulo se representa del siguiente modo (Martínez-Garrido y Murillo, 2014, p.6):

$$\begin{aligned}
 Y_{ij} &= \beta_{0j} + e_{ij} \\
 \beta_{0j} &= \beta_0 + u_{0j} \\
 u_{0j} &\sim N(0, \sigma_{u0}^2) \\
 e_{ij} &\sim N(0, \sigma_e^2)
 \end{aligned}$$

Y_{ij} es el rendimiento en pensamiento computacional del estudiante i en el centro educativo j .

β_0 es la media general en el rendimiento entre los centros.

β_{0j} es el promedio del rendimiento del centro j -ésimo.

u_{0j} es la desviación media del centro educativo j respecto de la puntuación real, asumiendo una distribución normal de media 0 y varianza σ_{u0}^2

e_{ij} es la varianza residual en el primer nivel o efecto que expresa la desviación en el rendimiento de los alumnos, que asumen una distribución normal de media 0 y varianza σ_e^2

β_{0j} σ_{u0}^2 (varianza del nivel 2) y σ_e^2 (varianza del nivel 1).

En las ecuaciones 1-3, $\overline{Y_{ij}}$ representa los resultados esperados en pensamiento computacional del alumno i en el centro j ; $\overline{\beta_{0j}}$, el intercepto estimado para cada centro j ; $\overline{e_{ij}}$, el residuo del estudiante i perteneciente al centro j ; $\overline{X_{kij}}$ comprende las variables que muestran k características del estudiante i en el centro j y $\overline{Z_{lj}}$ representa l características del centro j . Los efectos aleatorios se simbolizan con $\overline{\mu_j}$ (a nivel de centro) y $\overline{\varepsilon_{ij}}$ (a nivel de estudiante) (Escardíbul y Mediavilla, 2016; Tourón et al., 2023).

La ecuación 4 es el resumen de las tres ecuaciones anteriores

$$Y_{ij} = \beta_{0j} + \sum_{k=1}^n \beta_{1j} X_{kij} + \varepsilon_{ij} \quad \varepsilon_{ij} \sim N(0, \sigma^2) \quad (1)$$

$$\beta_{0j} = \gamma_{00} + \sum_l \gamma_{01} Z_{lj} + \mu_{0j} \quad \mu_{0j} \sim N(0, \tau_0) \quad (2)$$

$$\beta_{1j} = \gamma_{10} \mu_{1j} \sim N(0, \tau_1) \quad (3)$$

$$Y_{ij} = \gamma_{00} + \gamma_{10} X_{kij} + \gamma_{01} Z_{lj} + \mu_{0j} + \varepsilon_{ij} \quad (4)$$

Rendimiento en Pensamiento Computacional $_{ij} = \beta_{0j} + \beta_{1j} \text{Género}_{ij} + \beta_{2j} \text{ESC}_{ij} + \beta_{3j} \text{Competencia_Digital}_{ij} + \beta_{4j} \text{Uso_TIC}_{ij} + \beta_{5j} \text{Recursos_TIC_casa}_{ij} + \beta_{6j} \text{Recursos_TIC_centro}_j + \beta_{7j} \text{Titularidad}_j + \beta_{8j} \text{Área}_j + e_{ij}$

La Tabla 4 presenta los resultados del modelo nulo. El parámetro fijo informa sobre el valor del intercepto o rendimiento medio observado en pensamiento computacional para los sujetos que forman la muestra (484.066 puntos).

Tabla 4
Estimación del modelo nulo

Parte fija	
Parámetro	Estimación (Error estándar)
Constante	484.066 (1.223)
Parte aleatoria (Varianza en el rendimiento en pensamiento computacional)	
Nivel 1. Alumnado	6149.597 (60.342)
Nivel 2. Centro	1224.066 (75.382)
Razón de verosimilitud	357993.904
Número de parámetros	3

Fuente: Elaboración propia

La parte aleatoria del modelo nulo señala las varianzas de los residuos en los dos niveles establecidos. Un parámetro es significativo ($\alpha = .05$) si el cociente entre la estimación del parámetro y su error típico es superior a 1.96 (Gaviria & Castro, 2004). En este sentido, los parámetros resultan estadísticamente significativos en los dos niveles, de modo que hay diferencia entre alumnos ($6149.597 / 50.342 > 1.96$) y entre centros educativos ($1224.066 / 65.382 > 1.96$). Estos parámetros significativos señalan la existencia de varianza no explicada en los dos niveles, que justifica seguir con la expansión del modelo para explicar la mayor cantidad de varianza posible (Rodríguez-Mantilla et al., 2018).

La razón de verosimilitud del modelo nulo tiene un valor de 357993.904 para un modelo con 3 parámetros, que se comparará con el modelo definitivo.

Se ha realizado una prueba T de Student a fin de comprobar diferencias entre las medias de los chicos y las chicas en la competencia digital. Los resultados muestran diferencias significativas ($\text{Sig.} < .05$) en función del género (Chicos = 2.13; Chicas = 1.07).

El Coeficiente de Correlación Intraclase (CCI) representa el grado de variabilidad que existe entre los diferentes centros en comparación con la variabilidad existente entre los estudiantes del mismo centro (Pardo et al., 2007).

$$CCI = 1224.066 / (6149.597 + 1224.066) = 0.1660$$

Este valor indica que el 16% de la varianza es varianza entre centros, es decir, es el porcentaje de la varianza no explicada por los predictores que se puede atribuir a la variable de agrupamiento en el nivel 2.

El valor anterior muestra homogeneidad dentro del nivel 2, que justifica el uso de modelos jerárquicos lineales.

La Tabla 5 presenta la parte fija y la parte aleatoria del modelo definitivo, que recogen el valor del parámetro y su error típico entre paréntesis.

Tabla 5
Modelo definitivo

Parte fija	
Constante	460.57 (3.170)
Género	-4.151 (0.809)
Contexto socioeconómico del alumnado	10.96 (0.448)
Competencia digital del alumnado	6.085 (0.303)
Uso de las TIC para realizar actividades de pensamiento computacional	2.025 (0.418)
Disponibilidad y uso de las TIC en casa	8.149 (0.103)
Disponibilidad de TIC en el centro	4.293 (0.192)
Titularidad del centro	2.803 (0.397)
Área donde se localiza el centro	No significativo
Sexo*Competencia Digital	-2.356 (0.329)
Parte aleatoria	
Entre estudiantes	4807.936 (45.02)
Entre centros	572.141 (39.241)
Razón de verosimilitud	173420.684
Número de parámetros	12

Fuente: Elaboración propia.

Según los parámetros de la parte fija del modelo, el rendimiento medio es igual a 460.57 puntos en pensamiento computacional. Según la operacionalización de las variables, este valor se refiere al rendimiento medio estimado para estudiantes varones con un nivel socioeconómico y cultural medio. Los resultados muestran la significatividad de las covariables explicativas que se han seleccionado y que resultaron estables en el modelo nulo.

Las chicas presentan un menor rendimiento en pensamiento computacional que los chicos, que explica la brecha de género en las puntuaciones medias obtenidas (Chicos = 489.71; Chicas = 481.98).

El nivel socioeconómico del alumnado incide en el rendimiento, de modo que los estudiantes procedentes de familias con mayor renta tienen más puntos. A medida que aumenta un punto la media del nivel socioeconómico del alumnado, el rendimiento medio aumenta 10.96 puntos.

La competencia digital del alumnado para realizar una serie de tareas con recursos digitales también influye sobre el rendimiento, pues a medida que aumenta un punto la capacidad del estudiante para realizar una serie de tareas con las TIC, su rendimiento aumenta 6.085 puntos. Sin embargo, si el estudiante es chica, su rendimiento disminuye 2.356 puntos, lo cual pone de relieve que la competencia digital de los chicos es mayor que la de las chicas.

El uso de las TIC para realizar actividades de codificación o algoritmo tiene un efecto positivo y significativo en el rendimiento. A medida que aumenta un punto la frecuencia con la que el alumnado usa las TIC, su rendimiento aumenta 2.025 puntos.

La disponibilidad y el uso de las TIC en casa tiene un efecto significativo y positivo sobre el rendimiento.

La disponibilidad de TIC en el centro tiene un efecto significativo y positivo sobre el rendimiento del alumnado.

La titularidad del centro ha resultado un predictor significativo del rendimiento, a favor de los centros privados, que obtienen 2.803 puntos más que los centros públicos.

El área donde se localiza el centro no ha resultado ser un predictor significativo del rendimiento en pensamiento computacional.

Para calcular la bondad de ajuste del modelo definitivo con respecto al nulo, se compara la razón de verosimilitud de ambos modelos. Los resultados muestran una diferencia de un chi-cuadrado de 184573.22 con 9 grados de libertad, que resulta significativo al 0.01, lo cual confirma un mejor ajuste del modelo definitivo con respecto al nulo.

El Coeficiente R^2 expresa la proporción de varianza de la variable dependiente que se explica por los predictores incluidos en el modelo definitivo, como resultado de comparar los parámetros aleatorios de este modelo con los del modelo nulo (Snijders & Bosker, 2012). Los predictores incluidos en el modelo explican el 22% de las diferencias entre los estudiantes ($R^2= 0.2181$). Tourón et al. (2023) señalan que este valor es esperable en las evaluaciones a gran escala, que no incluyen variables importantes en el nivel de los estudiantes. Asimismo, las variables predictoras explican el 53% de la variabilidad entre centros educativos ($R^2= 0.5325$), lo cual demuestra la importancia de las variables contextuales.

4. Discusión

El objetivo de este trabajo ha sido conocer la influencia de los predictores del rendimiento en pensamiento computacional de los estudiantes españoles que han participado en PISA 2022. Para ello, se ha estimado una regresión múltiple multinivel, que ha permitido analizar simultáneamente los efectos significativos de un conjunto de variables independientes sobre el rendimiento a dos niveles (Estudiantes y Centros).

En cuanto a las variables del primer nivel (Estudiante):

-El sexo ha resultado ser un predictor significativo del rendimiento en pensamiento computacional, siendo las chicas quienes obtienen menos puntos que los chicos, que coincide con los resultados de otras investigaciones (Román González et al., 2018; Villalustre, 2024), pues ellas muestran menos confianza que ellos en el desarrollo de algoritmos y en la depuración de programas (Polat et al., 2021; Tsai et al., 2019) y más ansiedad hacia la adquisición de habilidades relacionadas con la programación (Chan et al., 2021). Asimismo, los resultados difieren de otros estudios (Herrero-Álvarez et al., 2023; Uslu, 2023), que no encontraron diferencias en función del sexo.

-El contexto socioeconómico del alumnado es un factor de impacto en el rendimiento, lo cual es coherente con los resultados de otras investigaciones (Coleman et al., 1966; Lee & Borgonovi, 2022; López et al., 2023; Walkington et al., 2018), pues los alumnos que proceden de contextos desfavorecidos cuentan con menos oportunidades de alfabetización en pensamiento computacional que aquellos de entornos favorecidos. Esto se traduce en dificultades para poner en práctica los conocimientos en la resolución de problemas (Kang & Cogan, 2022; Pivovarova & Powers, 2019).

-La competencia digital ha resultado ser un factor significativo que predice el rendimiento, en línea con los resultados de otras investigaciones (Jun et al., 2017; Wei et al., 2021), que demuestran que la confianza que el alumnado tiene en sus propias capacidades para usar las tecnologías de manera eficiente aumenta su motivación hacia el aprendizaje de conceptos sobre pensamiento computacional (Liao et al., 2022; Moreira-Fontán et al., 2019). Asimismo, las chicas muestran menos nivel de competencia digital que los chicos (Lucas et al., 2022; Niño-Cortés et al., 2023).

-El uso de las TIC para realizar actividades de codificación o algoritmo es un predictor significativo del rendimiento, que coincide con los resultados de otros estudios (Caballero-González & García-Valcárcel, 2020; Esteve-Mon et al., 2020; Juskeviciene & Dagiene, 2018; Loureiro et al., 2022; Rodríguez-Martínez et al., 2020), que demuestran la relación entre la competencia digital para solventar problemas y el pensamiento computacional.

Con respecto a las variables del segundo nivel, la disponibilidad de recursos TIC en la escuela es un predictor significativo del rendimiento (Escardíbul & Mediavilla, 2016), de modo que los recursos con los que cuenta un centro educativo tienen un gran impacto sobre el desempeño académico (Quiroz et al., 2018) y favorecen la adquisición de conceptos sobre pensamiento computacional (Lee et al., 2023).

-La titularidad del centro ha resultado ser un predictor significativo, a favor de los centros privados (Sun et al., 2023), que proporcionan experiencias formativas sobre pensamiento computacional en mayor medida que las escuelas públicas (Martínez & Echeveste, 2015). -El área donde se localiza el centro no ha resultado ser un predictor significativo, que contradice los resultados del estudio de Kale et al. (2018) y coincide con el trabajo de Aguayo-Téllez & Martínez-Rodríguez (2020).

5. Conclusiones

En este trabajo se llegan a una serie de conclusiones con implicaciones en la práctica educativa:

-En primer lugar, la diferencia de rendimiento entre los chicos y las chicas en el rendimiento en pensamiento computacional al finalizar la ESO sugiere la necesidad de promover programas sobre pensamiento computacional en los centros educativos a fin de fomentar la vocación de los estudiantes en las disciplinas STEM (*Science, Technology, Engineering and Mathematics, en inglés; Ciencia, Tecnología, Ingeniería y Matemáticas*).

-En segundo lugar, el impacto de la disponibilidad de recursos TIC sobre el rendimiento pone de relieve la necesidad de dotar de más recursos a los centros públicos y desfavorecidos para desarrollar actividades de pensamiento computacional.

-En tercer lugar, dado el efecto del uso de las TIC en tareas relacionadas con la codificación sobre el rendimiento, se recomienda el uso de aplicaciones para desarrollar el pensamiento computacional desde el primer curso de la ESO.

-En cuarto lugar, la competencia digital tiene un efecto significativo en la adquisición del pensamiento computacional, que sugiere la necesidad de reforzar la competencia digital del alumnado para realizar de forma eficaz un conjunto de actividades, por ejemplo, crear un programa de ordenador en Scratch.

Esta investigación ha demostrado el efecto de una serie de predictores sobre el rendimiento en pensamiento computacional de los estudiantes españoles que han participado en PISA 2022, que contribuye al conocimiento de los factores que inciden en la adquisición de competencias fundamentales para afrontar los retos que plantea la Sociedad del Conocimiento.

Fecha de finalización de la redacción definitiva del artículo: 14 de enero de 2024

Presentación del artículo: 15 de enero de 2024
Fecha de aprobación: 21 de noviembre de 2024
Fecha de publicación: 8 de enero de 2025

Ortega-Rodríguez, P.J. (2025). PISA 2022. Predictores del rendimiento en pensamiento computacional en Educación Secundaria en España. <i>RED. Revista de Educación a Distancia</i> , 25(81). http://dx.doi.org/10.6018/red.600641
--

El autor no ha utilizado LLM para la redacción de este artículo:

Este artículo no ha utilizado para su redacción textos provenientes de un LLM (ChatGPT u otros).

Financiación

Este trabajo no ha recibido ninguna subvención específica de los organismos de financiación en los sectores públicos, comerciales o sin fines de lucro.

Referencias

- Adell, J., Llopis, M. A., Esteve, F. M., & Valdeolivas, M. G. (2019). El debate sobre el pensamiento computacional en educación. *RIED. Revista Iberoamericana de Educación a Distancia*, 22(1), 171-186. <https://doi.org/10.5944/ried.22.1.22303>
- Aguayo-Téllez, E., & Martínez-Rodríguez, F.E. (2020). Early school entrance and middle-run academic performance in Mexico: evidence for 15-year-old students from the PISA test. *Large-scale Assessments in Education*, 8(1), 1-15. <https://doi.org/10.1186/s40536-020-00089-8>
- Berland, M., & Wilensky, U. (2015). Comparing virtual and physical robotics environments for supporting complex systems and computational thinking. *Journal of Science Education and Technology*, 24(5), 628-647. <https://doi.org/10.1007/s10956-015-9552-x>
- Caballero-González, Y.A., & García-Valcárcel, A. (2020). Fortaleciendo el pensamiento computacional y habilidades sociales mediante actividades de aprendizaje con robótica educativa en niveles escolares iniciales. *Píxel-Bit. Revista de Medios y Educación*, (58), 117-142. <https://doi.org/10.12795/pixelbit.75059>
- Cabero-Almenara, J., & Palacios-Rodríguez, A. (2020). Marco Europeo de Competencia Digital Docente «DigCompEdu» y cuestionario «DigCompEdu Check-In». *EDMETIC, Revista de Educación Mediática y TIC*, 9(1), 213-234. <https://doi.org/10.21071/edmetic.v9i1.12462>
- Chan, S.W., Looi, C.K., & Sumintono, B. (2021). Assessing computational thinking abilities among Singapore secondary students: a Rasch model measurement analysis. *Journal of Computers in Education*, 8(2), 213-236. <https://doi.org/10.1007/s40692-020-00177-2>
- Chang, I. (2023). Early numeracy and literacy skills and their influences on fourth-grade mathematics achievement: a moderated mediation model. *Large-scale Assessments in Education*, 11(18), 1-15. <https://doi.org/10.1186/s40536-023-00168-6>

- Coleman, J.S., Campbell, E.Q., Hobson, C.J., McPartland, J., Mood, A.M., Weinfeld, F.D., & York, R.L. (1966). *Equality of Educational Opportunity*. U.S. Department of Health, Education y Welfare Office of Education. National Center for Educational Statistics.
- Escardíbul, J.O., & Mediavilla, M. (2016). El efecto de las TIC en la adquisición de competencias. Un análisis por tipo de centro educativo. *Revista Española de Pedagogía*, 74(264), 317-335.
- Esteve-Mon, F. M., Llopis, M. Ángeles, & Adell-Segura, J. (2020). Digital competence and computational thinking of student teachers. *International Journal of Emerging Technologies in Learning (iJET)*, 15(02), 29–41. <https://doi.org/10.3991/ijet.v15i02.11588>
- Fraillon, J., Ainley, J., Schulz, W., Duckworth, D., & Friedman, T. (2019). Computational thinking framework. En J. Fraillon, J. Ainley, W. Schulz, D. Duckworth, & T. Friedman (Coords.), *IEA International Computer and Information Literacy Study 2018 Assessment Framework* (pp. 25–31). Springer International Publishing. https://doi.org/10.1007/978-3-030-19389-8_3
- García-Peñalvo, F. J., & Mendes, A. J. (2018). Exploring the computational thinking effects in pre-university education. *Computers in Human Behavior*, 80, 407–411. <https://doi.org/10.1016/j.chb.2017.12.005>
- Gaviria, J.L., & Castro, M. (2004). *Modelos jerárquicos lineales*. La Muralla.
- Goldstein, H. (2003). *Multilevel Statistical Models*. Hodder Arnold.
- González-Betancor, S.M., López-Puig, A., & Cardenal, M.E. (2021). Digital inequality at home. The school as compensatory agent. *Computers & Education*, 168, 1-12. <https://doi.org/10.1016/j.compedu.2021.104195>
- Gubbels, J., Swart, N.M., & Groen, M.A. (2020). Everything in moderation: ICT and reading performance of Dutch 15-year-olds. *Large-scale Assessments in Education*, 8(1), 1-14. <https://doi.org/10.1186/s40536-020-0079-0>
- Guggemos, J. (2021). On the predictors of computational thinking and its growth at the high-school level. *Computers & Education*, 161, 1-15. <https://doi.org/10.1016/j.compedu.2020.104060>
- Hann, T. (2020). Investigating the impact of teacher practices and noncognitive factors on mathematics achievement. *Research in Education*, 108(1), 22-45. <https://doi.org/10.1177/0034523719842601>
- Herrero-Álvarez, R., Miranda, G., León, C., & Segredo, E. (2023). Engaging primary and secondary school students in computer science through computational thinking training. *IEEE Transactions on Emerging Topics in Computing*, 11(1), 56-69. <https://doi.org/10.1109/TETC.2022.3163650>
- Hsu, Y.C., Roote, N., & Ching, Y.H. (2019). Computational Thinking Educational Policy Initiatives (CTEPI) across the globe. *TechTrends*, 63(3), 260-270. <https://doi.org/10.1007/s11528-019-00384-4>
- International Society for Technology in Education (ISTE) (9 de diciembre de 2023). *Computational thinking in K-12 Education. Teacher resources*. <https://bit.ly/41emUYE>

- Jun, S., Han, S., & Kim, A. (2017). Effect of design-based learning on improving computational thinking. *Behaviour & Information Technology*, 36(1), 43-53. <https://doi.org/10.1080/0144929X.2016.1188415>
- Juskeviciene, A., & Dagiene, V. (2018). Computational thinking relationship with digital competence. *Informatics in Education*, 17(2), 265-284. <https://doi.org/10.15388/infedu.2018.14>
- Kale, U., Akcaoglu, M., Cullen, T., Goh, D. (2018). Contextual factors influencing access to teaching computational thinking. *Computers in the Schools*, 35(2), 69-87. <https://doi.org/10.1080/07380569.2018.1462630>
- Kang, H., & Cogan, L. (2022). The differential role of socioeconomic status in the relationship between curriculum-based Mathematics and Mathematics literacy: the link between TIMSS and PISA. *International Journal of Science and Mathematics Education*, 20(1), 133-148. <https://doi.org/10.1007/s10763-020-10133-2>
- Kerlinger, F., & Lee, H. (2002). *Investigación del comportamiento. Métodos de investigación en Ciencias Sociales*. McGraw-Hill.
- Lee, J., & Borgonovi, F. (2022). Relationships between family socioeconomic status and Mathematics achievement in OECD and non-OECD countries. *Comparative Education Review*, 66(2), 199-227. <https://doi.org/10.1086/718930>
- Lee, A.W., Liang, j.C., Hsu, C.Y., Chien, F.P., & Tsai, M.J. (2023). Exploring potential factors to students' computational thinking: Interactions between gender and ICT-resource differences in taiwanese junior high schools. *Educational Technology & Society*, 26(3), 176-189. [https://doi.org/10.30191/ETS.202307_26\(3\).0013](https://doi.org/10.30191/ETS.202307_26(3).0013)
- Liao, C.H., Chiang, C.T., Chen, I.C., & Parker, K.R. (2022). Exploring the relationship between computational thinking and learning satisfaction for non-STEM college students. *International Journal of Educational Technology in Higher Education*, 19(43), 1-21. <https://doi.org/10.1186/s41239-022-00347-5>
- Lopes, J., Oliveira, C., & Costa, P. (2022). Determinantes escolares y de los estudiantes en el rendimiento lector: un análisis multinivel con estudiantes portugueses. *Revista de Psicodidáctica*, 27(1), 29-37. <https://doi.org/10.1016/j.psicod.2021.05.001>
- López, V., Salgado, M., & Berkowitz, R. (2023). The contributions of school and classroom climate to mathematics test scores: a three-level análisis. *School Effectiveness and School Improvement*, 34(1), 43-64. <https://doi.org/10.1080/09243453.2022.2096645>
- Loureiro, A.C., Meirinhos, M., Osório, A.J., & Valente, L. (2022). Computational thinking in teacher digital competence frameworks. *Revista Prisma Social*, (38), 77-93. <https://revistaprismasocial.es/article/view/4783>
- Lucas, M., Bem-Haja, P., Santos, S., Figueiredo, H., Ferreira, M., & Amorim, M. (2022). Digital proficiency: Sorting real gaps from myths among higher education students. *British Journal of Educational Technology*, 53(6), 1885-1914. <https://doi.org/10.1111/bjet.13220>
- Martínez, M.C., & Echeveste, M.E. (2015). Representaciones de estudiantes de primaria y secundaria sobre las Ciencias de la Computación y su oficio. *RED-Revista de Educación a Distancia*, 46(13), 1-38. <https://doi.org/10.6018/red/46/13>

- Ministerio de Educación, Formación Profesional y Deportes. (8 de diciembre de 2023a). *Marco para las pruebas de Matemáticas. PISA 2022*. <https://bit.ly/475G9VT>
- Ministerio de Educación, Formación Profesional y Deportes. (9 de diciembre de 2023b). *PISA 2022. Programa para la Evaluación Internacional de los Estudiantes. Informe Español*. <https://bit.ly/46Qt9mO>
- Ministerio de Educación y Formación Profesional. (9 de diciembre de 2023). *Las cifras de la educación en España: Estadísticas e indicadores. Edición 2022*. <https://bit.ly/4ayAjiw>
- Moreira-Fontán, E., García-Señorán, M., Conde-Rodríguez, A., & González, A. (2019). Teachers' ICT-related self-efficacy, job resources, and positive emotions: Their structural relations with autonomous motivation and work engagement. *Computers & Education, 134*, 63-77. <https://doi.org/10.1016/j.compedu.2019.02.007>
- Niño-Cortés, L.M., Grimalt-Álvaro, C., Lores-Gómez, B., & Usart, M. (2023). Brecha digital de género en secundaria: diferencias en competencia autopercibida y actitud hacia la tecnología. *Educación XXI, 26*(2), 299-322. <https://doi.org/10.5944/educxx1.134587>
- OECD. (16 de diciembre de 2023). *PISA 2022 Assessment and Analytical Framework*. <https://doi.org/10.1787/dfe0bf9c-en>
- Papert, S. (1980). *Mindstorms: Children, computers, and powerful ideas*. Basic Books.
- Pardo, A., Ruiz, M.A., & San Martín, R. (2007). Cómo ajustar e interpretar modelos multinivel con SPSS. *Psicothema, 19*(2), 308-321.
- Picado-Arce, K., Matarrita-Muñoz, S., Núñez-Sosa, O., & Zúñiga-Céspedes, M. (2021). Facilitadores del desarrollo del pensamiento computacional en estudiantes costarricenses. *Comunicar, 68*, 85-96. <https://doi.org/10.3916/C68-2021-07>
- Pivovarova, M., & Powers, J.M. (2019). Generational status, immigrant concentration and academic achievement: comparing first and second-generation immigrants with third-plus generation students. *Large-scale Assessments in Education, 7*(7), 1-18. <https://doi.org/10.1186/s40536-019-0075-4>
- Polat, E., Hopcan, S., Kucuk, S., & Sisman, B. (2021). A comprehensive assessment of secondary school students' computational thinking skills. *British Journal of Educational Technology, 52*(5), 1965-1980. <https://doi.org/10.1111/bjet.13092>
- Quiroz, S.S., Dari, N.L., & Cervini, R.A. (2018). Nivel socioeconómico y brecha entre educación secundaria pública y privada en Argentina. Los datos de PISA 2015. *REICE. Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación, 16*(4), 79-97. <https://doi.org/10.15366/reice2018.16.4.005>
- Restrepo-Palacio, S. & Segovia, Y. M. (2020). Diseño y validación de un instrumento de evaluación de la competencia digital en Educación Superior. *Ensaio: Avaliação e Políticas Públicas em Educação, 28*(109), 932-961. <https://doi.org/10.1590/s0104-40362020002801877>
- Rodríguez-Mantilla, J.M., Fernández-Díaz, M.J., & Jover, G. (2018). PISA 2015: Predictores del rendimiento en Ciencias en España. *Revista de Educación, (380)*, 75-102. <https://doi.org/10.4438/1988-592X-RE-2017-380-373>

- Rodríguez-Martínez, J.A., González-Calero, J.A., & Sáez-López, J.M. (2020). Computational thinking and mathematics using Scratch: an experiment with sixth-grade students. *Interactive Learning Environments*, 28(3), 316-327. <https://doi.org/10.1080/10494820.2019.1612448>
- Román-González, M., Pérez-González, J.C., Moreno-León, J., & Robles, G. (2018). Extending the nomological network of computational thinking with non-cognitive factors. *Computers in Human Behavior*, 80, 441-459. <https://doi.org/10.1016/j.chb.2017.09.030>
- Sayans-Jiménez, P., Vázquez-Cano, E., & Bernal-Bravo, C. (2018). Influencia de la riqueza familiar en el rendimiento lector del alumnado en PISA. *Revista de Educación*, (380), 129-155. <https://doi.org/10.4438/1988-592X-RE-2017-380-375>
- Snijders, T. A., & Bosker, R.J. (2012). *Multilevel analysis: An introduction to basic and advanced multilevel modeling*. Sage Publications.
- Sun, L., You, X., & Zhou, D. (2023). Evaluation and development of STEAM teachers' computational thinking skills: Analysis of multiple influential factors. *Education and Information Technologies*, (28), 14493-14527. <https://doi.org/10.1007/s10639-023-11777-7>
- Tourón, J., López-González, E., Lizasoain, L., & Navarro, E. (2023). *Análisis de datos y medida en educación*. (Vol. II). UNIR Editorial.
- Tsai, M.J., Wang, C.Y., & Po-Fen, H. (2019). Developing the computer programming self-efficacy scale for computer literacy education. *Journal of Educational Computing Research*, 56(8), 1345-1360. <https://doi.org/10.1177/0735633117746747>
- Uslu, N.A. (2023). How do computational thinking self-efficacy and performance differ according to secondary school students' profiles? The role of computational identity, academic resilience, and gender. *Education and Information Technologies*, 28(5), 6115-6139. <https://doi.org/10.1007/s10639-022-11425-6>
- Villalustre, L. (2024). Análisis del nivel de pensamiento computacional de los futuros maestros: una propuesta diagnóstica para el diseño de acciones formativas. *Píxel-Bit. Revista de Medios y Educación*, (69), 169-194. <https://doi.org/10.12795/pixelbit.101205>
- Walkington, C., Clinton, V., & Shivraj, P. (2018). How readability factors are differentially associated with performance for students of different backgrounds when solving mathematics word problems. *American Educational Research Journal*, 55(2), 362-414. <https://doi.org/10.3102/0002831217737028>
- Wei, X., Lin, L., Meng, N., Tan, W., Kong, S.C., & Kinshuk, K. (2021). The effectiveness of partial pair programming on elementary school students' Computational Thinking skills and self-efficacy. *Computers & Education*, 160 (104023), 1-18. <https://doi.org/10.1016/j.compedu.2020.104023>
- Wing, J. M. (2006). Computational thinking. *Communications of the ACM*, 49(3), 33-35. <https://doi.org/10.1145/1118178.1118215>.
- Wu, M., & Adams, F. (2002). *Manual de análisis de datos de PISA 2003: usuarios de SPSS*. OCDE.