



ID del documento: SiE-Vol.2.N.9.002.2025

Tipo de artículo: Revisión

Prácticas de autorregulación del aprendizaje en Ciencias de la Computación: Una revisión sistemática

Self-Regulated Learning Practices in Computer Science: A Systematic Review

Autores:

Paulo Cesar Coronado Sánchez¹, Carlos Javier Mosquera Suárez²

¹Universidad Distrital Francisco José de Caldas, Bogotá, Colombia,

paulocoronado@udistrital.edu.co, <https://orcid.org/0000-0003-2980-2376>

²Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, cmosquera@udistrital.edu.co

<https://orcid.org/0000-0001-8640-0803>

Corresponding Author: Coronado Sánchez, Paulo Cesar, paulocoronado@udisrital.edu.co

Reception: 04-June-2025 **Acceptance:** 07-July-2025 **Publication:** 05-September-2025

How to cite this article:

Coronado Sánchez, P. C., & Mosquera Suárez, C. J. (2025). Prácticas de autorregulación del aprendizaje en Ciencias de la Computación: Una revisión sistemática. Sapiens in Education, 2(9), 1-20. <https://doi.org/10.71068/ss2rft29>



Resumen

Los estudiantes universitarios de áreas afines a ciencias de la computación, como la programación, enfrentan desafíos como resolver problemas complejos, comprender conceptos abstractos y la organización lógica de soluciones. Ante estas exigencias, la autorregulación del aprendizaje se reconoce como una competencia necesaria para planificar, monitorear y reflexionar sobre el propio proceso cognitivo, contribuyendo así al desarrollo del pensamiento computacional y una mejora sostenida del rendimiento académico. Esta revisión sistemática analizó 59 estudios publicados entre 2021 y 2025, consultados en las plataformas académicas ERIC, Open Alex, Scopus, Scilit y Google Scholar, con el objetivo de identificar estrategias de autorregulación del aprendizaje en este campo, dada la escasez de estudios recientes que las analizan de forma estructurada. Se identificaron 402 estrategias, clasificadas en tres categorías principales: cognitivas (35 %), metacognitivas (34 %) y de gestión de recursos (31 %). Las cognitivas incluyen estrategias como descomposición de problemas, depuración de errores, elaboración y práctica. Las metacognitivas abarcaron planificación, monitoreo y reflexión. Las de gestión de recursos comprendieron la organización del tiempo, la regulación de la motivación, trabajo colaborativo, uso de plataformas tecnológicas y gamificación.

Palabras clave: Autorregulación del aprendizaje; Ciencias de la Computación; Educación superior; Estrategias de aprendizaje; Pensamiento computacional.

Abstract

University students in fields related to computer science, such as programming, face challenges like solving complex problems, understanding abstract concepts, and organizing logical solutions. In response to these demands, self-regulated learning is recognized as a necessary competence to plan, monitor, and reflect on one's own cognitive process, thereby contributing to the development of computational thinking and the sustained improvement of academic performance. This systematic review analyzed 59 studies published between 2021 and 2025, retrieved from academic platforms ERIC, Open Alex, Scopus, Scilit, and Google Scholar, with the aim of identifying self-regulated learning strategies in this field, given the scarcity of recent studies that analyze them in a structured manner. A total of 402 strategies were identified, classified into three main categories: cognitive (35%), metacognitive (34%), and resource management (31%). Cognitive strategies include problem decomposition, error debugging, elaboration, and practice. Metacognitive strategies encompassed planning, monitoring, and reflection. Resource management strategies involved time organization, motivation regulation, collaborative work, the use of technological platforms, and gamification.

Keywords: Self-Regulated Learning, Computer Science, Higher Education, Learning Strategies, Computational Thinking



1. INTRODUCCIÓN

Aprender a programar en áreas de las ciencias computacionales implica un reto para los estudiantes universitarios, especialmente en los inicios de su carrera, donde se suelen registrar altas tasas de abandono y bajo rendimiento académico (Cheng, 2021; Öztürk 2022; Menon et al., 2020). Estas dificultades están relacionadas con el desarrollo del pensamiento computacional, que se define como la capacidad de resolver problemas complejos usando razonamiento lógico, abstracción y estrategias algorítmicas (Lee & Choi 2023).

Ante este panorama, diversos estudios señalan que una de las razones de estas dificultades es la falta de autorregulación del aprendizaje (Dayimani y Padayachee, 2023; Soares et al., 2023), la cual permite a los estudiantes establecer planes, ejecutar y adaptar su propio proceso de aprendizaje de acuerdo con unos objetivos académicos (Zimmerman, 2002), así como autorregular su pensamiento, motivación y acciones, según sus objetivos y las demandas del entorno (Pintrich, 2000). Soares et al. (2021), Dayimani y Padayachee (2023), Öztürk (2022) y Menon (2021) indican que la autorregulación del aprendizaje en disciplinas afines a las computacionales permite a los estudiantes tener más conciencia de sus procesos cognitivos, identificar las dificultades que van apareciendo durante la resolución de problemas, persistir ante los desafíos propios del aprendizaje y adaptar estrategias para que el resultado sea un aprendizaje más efectivo y autogestionado.

A pesar del reconocimiento positivo de la autorregulación del aprendizaje en el ámbito universitario, la evidencia sistemática sobre las estrategias utilizadas por estudiantes de Ciencias de la Computación sigue siendo limitada (Cheng, 2021; Soares et al., 2023; Cheng et al., 2024; Ferreira et al., 2024), lo que dificulta comprender cómo autogestionan los retos asociados al aprendizaje en esta área.

En respuesta a esta brecha, la presente revisión sistemática busca identificar las estrategias de autorregulación que ponen en práctica los estudiantes en este campo, agrupadas en tres categorías: cognitivas, metacognitivas y gestión de recursos. Con ello, se pretende ofrecer insumos para el desarrollo de propuestas pedagógicas o tecnológicas que tiendan a promover un aprendizaje autorregulado y una mejora del rendimiento académico en estas áreas.

2. METODOLOGÍA

Esta revisión sistemática se realizó según los lineamientos PRISMA 2020 para la síntesis o metaanálisis de las investigaciones. Se seleccionaron los estudios publicados en inglés y español, durante el periodo comprendido entre el 2021 y el 2025, en revistas académicas revisadas por pares o tesis. Se excluyeron los estudios cuyo alcance no se centra en exponer estrategias de autorregulación de estudiantes universitarios de áreas afines a las ciencias de la computación. Las bases de datos consultadas fueron ERIC, Open Alex, Scopus, Scilit y Google Scholar. El proceso incluyó las fases de identificación, cribado e inclusión, y todos los registros fueron documentados en un repositorio público (Coronado, 2025).



2.1. Fase de identificación

La Tabla 1 descompone la pregunta de investigación propuesta para llevar a cabo esta revisión sistemática, junto con las palabras y frases claves, en español e inglés, que sirvieron para construir y adaptar las estrategias de búsqueda según el idioma y el motor consultado.

Tabla 1. Palabras y frases claves para la búsqueda de recursos.

¿Qué estrategias de autorregulación del aprendizaje	aplican los estudiantes universitarios	en áreas afines a las ciencias de la computación?
self-regulated learning metacognitive strategies self-directed learning motivation learning strategies aprendizaje autorregulado estrategias metacognitivas aprendizaje autodirigido estrategias de aprendizaje motivación	higher education university students undergraduate students educación superior estudiantes universitarios	computer programming computer science software engineering computational thinking coding programación de computadores ciencias de la computación pensamiento computacional

2.1.1. Proceso de recopilación de datos

Las sentencias de búsqueda y sus variaciones fueron ingresadas en las plataformas de las fuentes de información. La fecha inicial de búsqueda fue el 1 de enero de 2021 y la última fecha fue el 1 de julio de 2025.

2.2. Selección de los estudios

La selección de artículos fue un proceso de tres etapas semisupervisado.


2.2.1. Fase de identificación

En una primera fase se identificaron 486 en los motores de búsqueda, los cuales fueron importados a la herramienta Rayyan para el cribado, donde se detectó automáticamente un total de 272 registros duplicados y posteriormente se descartaron 156 de ellos (ver Figura 1).

2.2.2. Fase de selección

En la segunda etapa se analizaron 330 resúmenes de los estudios con apoyo de la herramienta Rayyan, 256 fueron descartados por no cumplir con los criterios de inclusión. Se preseleccionaron un total de 74 estudios; de estos, se excluyeron 6 por acceso restringido. Los 68 restantes fueron evaluados para su texto completo, excluyendo a 9 más por no ser relevantes o en un idioma no considerado.

Figura 1. Diagrama resultados Revisión Sistemática.



Fuente: Los autores.

2.2.3. Fase de inclusión

La fase final consistió en la organización y clasificación de los datos de los 59 estudios que fueron centralizados en el repositorio público (Coronado, 2025) a través de las siguientes tablas maestras:

Datos generales: Incluyen ID del estudio, título, autor(es), año, país, tipo de estudio, instrumentos aplicados, limitaciones, área de conocimiento y participantes.

Datos específicos: Relacionan las estrategias de autorregulación identificadas en los estudios, clasificadas por categoría, tipo y clase.

Estadísticas: Presentan frecuencias absolutas y relativas de los datos, permitiendo identificar patrones y caracterizar el enfoque y contexto de los estudios incluidos.



3. RESULTADOS

Las siguientes secciones presentan la síntesis de los aspectos generales y específicos de los 59 artículos revisados sistemáticamente en esta investigación.

3.1 Aspectos generales

La Tabla 2 presenta un extracto de los datos generales de los 59 trabajos incluidos en esta revisión. El detalle de esta tabla se puede consultar en el repositorio de acceso público (Coronado, 2025).

Tabla 2. Extracto de estudios seleccionados en la revisión sistemática

ID	Autor	Año	País	Tipo de estudio
1	Zhu et al., 2024)	2024	Estados Unidos	Mixto
2	Dayimani & Padayachee, 2023	2023	Sudáfrica	Revisión sistemática
3	Soares et al., 2023	2023	Brasil	Cualitativo

Fuente: Los autores.

El origen de las investigaciones correspondió a Europa (36 %), Asia (32 %), América del Norte (25 %), América Latina (15 %) y Oceanía (5 %). En los tipos de investigación desarrollados en los estudios, predominan las de tipo cuantitativo (44 %), seguidas de investigación mixta (25 %), cualitativa (19 %) y revisiones teóricas o sistemáticas (12 %).

En cuanto a la modalidad de estudio, el 49 % se realizó de forma virtual, un 27 % presenciales, y el 12 %, híbridos o no clasificados. Los trabajos se concentraron principalmente en el área de la programación (70 %) y los demás se relacionaron con disciplinas como bases de datos, informática e ingeniería de software.

Entre las limitaciones metodológicas más comunes en los estudios, destacan el uso de muestras pequeñas (53 %), la baja generalización de resultados (51%), la falta de datos cuantitativos (36 %), el uso de autoinformes (34 %) y el desarrollo en contextos limitados (31 %).

3.2 Aspectos específicos

3.2.1 Estrategias de autorregulación del aprendizaje identificadas

La Tabla 3 presenta un extracto de las estrategias de autorregulación del aprendizaje en áreas afines a las Ciencias de la Computación identificadas en los 59 estudios. El detalle de esta tabla se puede consultar en el repositorio de acceso público (Coronado, 2025).

En total, se identificaron 402 estrategias, clasificadas en tres categorías: 141 cognitivas (35 %), 138 metacognitivas (34 %) y 123 estrategias de gestión de recursos (31 %).

**Tabla 3. Extracto de estrategias de autorregulación del aprendizaje identificadas**

Id	Autor	Categoría	Tipo	Clase
1	Zhu et al., 2024	Cognitiva	Elaboración y organización de contenidos	Toma de notas y síntesis conceptual
2	Dayimani & Padayachee, 2023	Gestión de recursos	Acceso estratégico a recursos para reforzar el aprendizaje	Consulta de fuentes externas

Fuente: Los autores.

Estrategias cognitivas

Dentro de esta categoría se identificaron cuatro tipos de estrategias (ver Tabla 4), siendo la más destacada la “Resolución de Problemas y Pensamiento Crítico”, representada en un 45 % de los casos e involucró prácticas como descomponer problemas complejos, evaluar críticamente posibles soluciones y comprobar los resultados obtenidos.

En segundo lugar, las estrategias de “Corrección de Errores y Depuración” (25 %) que están orientadas a identificar y corregir fallos a través del análisis de mensajes de error, la retroalimentación automática y la mejora continua del código.

Por su parte, las estrategias de “Elaboración y Organización de Contenidos” (24 %) incluyen prácticas como aplicar conocimientos previos en nuevos contextos, el uso de organizadores visuales, la toma estructurada de notas y el empleo de analogías para facilitar la comprensión.

Finalmente, las estrategias de “Práctica Repetida y Ensayo” (6 %) agrupan acciones enfocadas en reforzar habilidades mediante ejercicios continuos, repetición para la memorización y entregas iterativas de programación.

Tabla 4. Estrategias de autorregulación del aprendizaje cognitivas

Tipo	%	Clase de estrategia	ID Estudios
Resolución de problemas y pensamiento crítico	64 45%	1. Aplicación práctica del conocimiento 2. Descomposición del problema 3. Discusión en grupo para comparar enfoques de solución 4. Evaluación crítica del proceso y los resultados 5. Verificación de salidas esperadas	[2, 3, 4, 7, 8, 9, 10, 13, 14, 16, 19, 20, 23, 24, 26, 31, 32, 33, 34, 35, 36, 37, 38, 39, 41, 43, 44, 45, 48, 49, 50, 51, 52, 53, 56]



Tipo	%	Clase de estrategia	ID Estudios
Corrección de errores y depuración	35 25%	1. Análisis de mensajes de error 2. Corrección inmediata 3. Detección de errores con retroalimentación automática 4. Optimización del código	[3, 6, 9, 10, 17, 21, 22, 28, 37, 40, 43, 45, 46, 47, 48, 50, 52, 54, 55, 56, 57]
Elaboración y organización de contenidos	34 24%	1. Conexión con conocimientos previos 2. Organización visual de la información 3. Representación gráfica de conceptos 4. Toma de notas y síntesis conceptual 5. Uso de analogías para comprender conceptos abstractos	[1, 2, 3, 4, 5, 6, 9, 10, 14, 17, 18, 19, 20, 23, 24, 26, 28, 33, 34, 38, 45, 46, 52, 53]
Práctica repetida y ensayo	8 6%	1. Entrega iterativa para validar el código. 2. Memorización mediante lectura repetida 3. Programación como práctica continua	[3, 4, 5, 9, 33, 34, 45, 52]
Total	141		

Fuente: Los autores.

Estrategias metacognitivas

En esta categoría se reúnen tres tipos de estrategias (ver Tabla 5). La más representativa fue la “Reflexión y Autoevaluación” (46 %), orientada al análisis de la propia actividad de aprendizaje. Incluye prácticas como la autoevaluación acompañada de docentes o compañeros, el uso de instrumentos estructurados para la autorreflexión y el diálogo estructurado entre pares para favorecer la toma de conciencia.

Le siguió “Monitoreo y Evaluación del Proceso Cognitivo” (30 %), centrada en el seguimiento activo del desempeño. Abarca la supervisión con retroalimentación de docentes, pares o sistemas automáticos, así como el uso consciente de herramientas como la inteligencia artificial para ajustar decisiones y estrategias.

Finalmente, las estrategias de “Planificación” orientadas a la organización previa de la actividad de aprendizaje (24 %). Incluía prácticas como la definición de las metas de aprendizaje, la organización paso a paso de una solución de software mediante diagramas o pseudocódigo, y el uso de herramientas tecnológicas para organizar y planificar el aprendizaje.

**Tabla 5. Estrategias de tipo metacognitivo**

Tipo	%	Clase de estrategia	ID Estudios
Monitoreo y evaluación del proceso cognitivo	42 (30%)	1. Supervisión del desempeño con retroalimentación de docentes o pares 2. Evidenciar el progreso del aprendizaje mediante registros digitales de trabajo. 3. Monitoreo y ajuste guiado por inteligencia artificial 4. Seguimiento del desempeño mediante retroalimentación automática 5. Seguimiento del desempeño mediante retroalimentación formativa	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 22, 24, 25, 27, 28, 30, 31, 36, 38, 39, 40, 42, 44, 46, 47, 48, 49, 50, 52, 53, 55, 56, 57, 59]
Planificación y establecimiento de metas	33 (24%)	1. Definir metas de aprendizaje 2. Planificación de soluciones mediante diagramas o pseudocódigo 3. Planificación paso a paso orientada al logro de metas 4. Rediseño de metas y estrategias a partir de retroalimentación 5. Uso de herramientas digitales para organizar y planificar el aprendizaje	[1, 2, 3, 4, 5, 6, 8, 9, 11, 13, 15, 19, 20, 22, 27, 28, 29, 34, 35, 37, 39, 40, 42, 45, 46, 48, 49, 50, 54, 55, 57, 58]
Reflexión y autoevaluación metacognitiva	63 (46%)	1. Autoevaluación con apoyo de docentes o pares 2. Revisión reflexiva del desempeño con retroalimentación automática 3. Autoevaluación guiada por instrumentos estructurados 4. Reflexión autónoma individual 5. Toma de conciencia mediante diálogo dirigido	[1, 2, 3, 4, 5, 6, 7, 8, 9, 11, 13, 14, 15, 16, 17, 19, 20, 21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 32, 35, 36, 37, 38, 40, 41, 42, 43, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58]
Total	138		

Fuente: Los autores.



Estrategias de gestión de recursos

Se encontraron seis tipos de estrategias dentro de esta categoría (ver Tabla 6). La más reconocida fue “Aprendizaje colaborativo y co-construcción” (28 %), basada en prácticas como la programación en parejas, el trabajo en grupo y la enseñanza entre pares. La siguió la estrategia “Acceso Estratégico a Recursos” (21 %) con el uso intencionado de materiales, foros, videos o personas para reforzar el aprendizaje.

El tipo de estrategias de “Motivación y Autoeficacia” (19 %) incorporó acciones orientadas a fortalecer la autoconfianza, la perseverancia y el compromiso con metas personales. Las estrategias de “Gestión del Tiempo y Entorno de Estudio” (15 %) reunieron prácticas como el establecimiento de rutinas, planificación de entregas y la priorización de tareas.

Al mismo tiempo, destacó las estrategias de “Uso Estratégico de Plataformas y Entornos Técnicos (15 %), usando herramientas digitales, simuladores y sistemas automatizados de retroalimentación. Por último, la gamificación (2 %) se concretó en la utilización puntual de recompensas y retos para mantener la motivación.

Tabla 6. Clase de estrategias de tipo Gestión de Recursos

Tipo	%	Clase de estrategia	ID Estudios
Aprendizaje colaborativo y co-construcción de estrategias	34 (28%)	1. Apoyo directo de personas expertas o pares 2. Apoyo personalizado por asistentes inteligentes 3. Compartir y validar estrategias entre pares 4. Desarrollo colaborativo de proyectos 5. Estudio grupal para compartir ideas y resolver ejercicios. 6. Participación en espacios de interacción académica 7. Programación en parejas 8. Refuerzo del conocimiento mediante enseñanza entre pares 9. Verbalización conjunta de ideas	[1, 2, 3, 4, 5, 6, 7, 8, 9, 14, 15, 20, 21, 24, 25, 26, 27, 28, 30, 32, 37, 43, 45, 48, 49, 51, 57, 59]
Acceso estratégico a recursos para reforzar el	26 (21%)	1. Apoyo directo de personas expertas o pares 2. Aprendizaje observacional entre compañeros 3. Consulta de fuentes externas	[1, 2, 3, 4, 5, 7, 9, 19, 20, 23, 33, 34, 37, 45, 48,



Tipo	%	Clase de estrategia	ID Estudios
aprendizaje		4. Revisión colaborativa de replays 5. Uso de recursos instruccionales	49, 50, 58]
Motivación y autoeficacia	23 (19%)	1. Confiar en uno mismo y seguir adelante. 2. Controlar emociones cuando algo sale mal. 3. Crear un ambiente agradable con el grupo. 4. Enfocarse en metas personales 5. Estudiar con interés y constancia 6. Motivarse con retos y reconocimientos 7. Recepción positiva de retroalimentación	[5, 9, 10, 12, 13, 16, 18, 22, 30, 31, 32, 37, 38, 39, 40, 42, 44, 59]
Gestión del tiempo y del entorno de estudio	19 (15%)	1. Establecimiento de horarios regulares 2. Establecimiento de rutinas y prioridades 3. Organización del tiempo para entregas 4. Preparación del entorno de estudio	[1, 2, 3, 4, 5, 7, 8, 15, 16, 19, 20, 27, 34, 37, 40, 45, 50]
Uso estratégico de plataformas y entornos técnicos	19 (15%)	1. Análisis de desempeño con métricas 2. Aplicación práctica en entornos simulados 3. Apoyo personalizado por asistentes inteligentes 4. Aprendizaje técnico autónomo en plataformas digitales 5. Autogestión del aprendizaje en entornos digitales 6. Exploración autodirigida con IA 7. Uso de comunidades digitales para aprender 8. Uso de entornos digitales estructurados con apoyo progresivo	[1, 2, 12, 21, 23, 26, 29, 36, 39, 41, 43, 45, 46, 51, 53, 58, 59]
Gamificación para estimular el aprendizaje	2 (2%)	1. Uso de elementos lúdicos o recompensas	[12, 29]

Fuente: Los autores.

4. DISCUSIÓN



Los resultados de esta revisión evidencian un creciente interés por comprender la autorregulación del aprendizaje en áreas afines a las Ciencias de la Computación, especialmente en los últimos años. Este enfoque ha cobrado relevancia en el contexto de la transformación digital de la educación, acompañado por un aumento en los estudios internacionales, particularmente en regiones con alto desarrollo tecnológico.

Las estrategias identificadas en los estudios analizados se distribuyen de forma equilibrada entre componentes cognitivos, metacognitivos y de gestión de recursos, lo que refleja una comprensión integral del aprendizaje autorregulado en disciplinas como la programación.

Estrategias cognitivas

El desarrollo del pensamiento crítico y la capacidad para resolver problemas son estrategias cognitivas frecuentes en el aprendizaje autorregulado en las Ciencias de la Computación, ya que permiten a los estudiantes universitarios analizar problemas complejos, activar conocimientos previos en situaciones prácticas y verificar salidas esperadas del código fuente, mejorando de este modo el razonamiento lógico y la autorregulación.

Una de las prácticas más comunes de esta categoría, es la descomposición y resolución de problemas que incluye habilidades como la interpretación y desglose paso a paso de un problema, el diseño y la adaptación de algoritmos, así como su traducción a un lenguaje de programación (Ferreira & Campos, 2023; Domino, 2024; Şen, 2023). Sin embargo, algunas investigaciones reconocen que los estudiantes, en especial los principiantes, resuelven problemas de forma apresurada o mecánica, sin detenerse a pensar en la lógica de lo que hacen ni en la calidad de las soluciones que obtienen (Soares et al., 2023; Chen & Hsu, 2024; Zhu et al., 2024). Además, cuando los estudiantes no tienen conocimientos previos suficientes, les cuesta entender lo que plantea el problema y se les dificulta encontrar una solución adecuada (Watanabe et al., 2025; Shin & Song, 2022).

La depuración y corrección de errores es otra estrategia identificada en esta categoría y les permite a los estudiantes identificar fallos, revisar la lógica y mejorar progresivamente el código. Los entornos con retroalimentación inmediata, como compiladores o plataformas inteligentes, potencian este proceso (Cloude et al, 2023; Wu et al, 2024). Aun cuando, varios estudios han mostrado que los estudiantes, tienden a enfocarse principalmente en corregir errores de sintaxis detectados por el compilador, sin comprender la causa del problema ni reflexionar sobre el funcionamiento general del código (Cloude et al., 2023; Ferreira & Campos, 2023). Además, cuando los entornos de trabajo ofrecen retroalimentación automática de manera limitada o poco clara, los estudiantes pueden frustrarse al no entender cómo corregir los errores (Luo, 2024; Wu et al., 2024). Por otro lado, si se apoyan excesivamente en estas herramientas, pueden volverse dependientes y no desarrollar habilidades para analizar y corregir errores (Paludo & Montresor, 2024).

La elaboración y organización de la información se utilizan también como una de las estrategias cognitivas autorreguladas que contribuyen para la comprensión y la transferencia



del conocimiento a nuevos contextos. Las prácticas como la toma de notas, la realización de esquemas visuales o la construcción de analogías, ayudan a representar con claridad conceptos abstractos (Zhu et al., 2024; Cheng, 2021). Aunque, se identificó que los estudiantes aplican poco estas estrategias, afectando la planificación efectiva del código (Domino, 2024; Ferreira & Campos, 2023).

La práctica continua es una estrategia útil en el aprendizaje autorregulado porque propicia que los estudiantes adquieran la destreza en programación, genere confianza y coadyuve a la interiorización de la escritura del código. No obstante, cuando esta práctica se realiza sin reflexión, la actividad puede volverse repetitiva y poco útil, haciendo que algunos estudiantes realicen los mismos ejercicios una y otra vez sin hacer ajustes ni corregir sus errores y, por lo tanto, no mejoren (Domino, 2024). Algunos estudios mencionan que los estudiantes con bajo rendimiento tienden a repetir instrucciones o pedir ayuda sin entender bien el contenido, lo que los limita para enfrentar la práctica de tareas complejas que requieren profundizar el aprendizaje (Lee & Choi, 2023; Cheng, 2021; Ferreira et al., 2024).

Estrategias metacognitivas

Las estrategias de “Reflexión y Autoevaluación” promovieron la autoconciencia del estudiante sobre la calidad de su aprendizaje. En este sentido, Ugulino & Ferreira Pires, 2021 y Lei et al., 2024, afirmaron que el uso de diarios o formularios estructurados facilitó la identificación de errores y el ajuste de estrategias, así como la autorregulación y la autoconfianza. En la misma línea, Soares et al. (2023), Ugulino y Xie et al. (2023) evidencian que la autoevaluación reflexiva, guiada por pares, docentes o retroalimentación automática, mejoró el rendimiento y la toma de decisiones. A pesar de lo anterior, algunos estudiantes expresaron desinterés por aplicar estas prácticas, considerando que son repetitivas, extensas o poco útiles (Öztürk, 2022; Haque et al., 2025; Türkmen et al., 2024). Asimismo, cuando la reflexión no es crítica, puede reforzar errores en lugar de corregirlos (Xie et al., 2023). También se evidenció que algunos estudiantes no reflexionan sobre cómo fue su participación o el trabajo realizado en equipo, lo que impide identificar oportunidades de mejora en contextos colaborativos (Ferreira & Campos, 2023).

Los autores Zhu et al. (2024), Margulieux et al. (2024) y Lei et al. (2024) ponen de manifiesto que el uso de la retroalimentación tecnológica mediante herramientas analíticas, paneles visuales y sistemas automatizados permitió que los estudiantes fueran capaces de monitorear y controlar su propio progreso, adaptar sus estrategias y detectar autónomamente errores durante la actividad. Pese a ello, algunos estudios indican que no todos los estudiantes hacen un uso efectivo de la retroalimentación automática de la que disponen en muchos sistemas de aprendizaje. En algunos casos ignoran los comentarios o repiten los mismos errores sin analizarlos (Arakawa et al., 2021; Cloude et al., 2023; Wu et al., 2024). Por otro lado, se ha observado que, aunque los paneles y herramientas de monitoreo ofrecen datos útiles, no siempre impulsan a los estudiantes a tomar decisiones o ajustar sus estrategias (Lei et al., 2024; Gao et al., 2022). Además, algunos autores informan que la retroalimentación automática puede, en ocasiones, ser poco clara o demasiado general y no resultar útil (Chen, 2023; Paludo & Montresor, 2024).



Estudios como los de Zhu et al. (2024), Öztürk (2022), Onah et al. (2021) y Susilowati et al. (2024) reconocen la importancia de dividir objetivos del aprendizaje en subtarear, organizarlas, priorizarlas y ajustar planes según el progreso, para favorecer la gestión del tiempo, reducir la procrastinación y actuar como un motor de motivación (Dayimani & Padayachee, 2023; Tsai et al., 2024). Aun así, a algunos estudiantes les resulta difícil aplicar estas estrategias de forma efectiva, ya que no planifican adecuadamente o no saben organizar las tareas, y en ocasiones posponen el cumplimiento de éstas, lo que afecta a su rendimiento progresivamente (Shin & Song, 2022; Onah et al., 2021; Torres et al., 2024). Por otro lado, algunos estudiantes mencionan que establecer metas puede dar como resultado una carga excesiva o se ven limitados por la falta de orientación clara al inicio de las actividades (Haque et al., 2025; Rebollo, 2024) o cuando no han sido entrenados previamente en el uso de estrategias autorreguladas (Onah et al., 2021).

Estrategias de gestión de recursos

El uso de estrategias de gestión de recursos evidenció cómo los estudiantes utilizan su entorno físico y sus medios digitales, así como el entorno social como soporte del aprendizaje autorregulado. Dentro de las estrategias de gestión de recursos, el aprendizaje colaborativo, el intercambio verbal de ideas y la enseñanza entre pares fortalecieron la comprensión conceptual, la motivación y el sentido de pertenencia (Ferreira et al., 2024; Zhu et al., 2024; Dayimani & Padayachee, 2023). Estas prácticas fueron especialmente efectivas en entornos virtuales interactivos, tales como foros, agentes inteligentes y plataformas asincrónicas. Incluso así, diferentes investigaciones apuntan que esa misma práctica puede generar riesgos de participación desigual o superficial. En trabajos en pareja o en grupo, algunos de los estudiantes tienden a asumir un rol pasivo o a delegar tareas, lo cual limita el beneficio de la práctica colaborativa (Magana et al., 2024; Tsai et al., 2024). Además, cuando no existe una efectiva organización o distribución de roles, surgen problemas de comunicación, falta de coordinación o desigualdad en la carga de trabajo (Torres et al., 2024; Kazemitabar et al., 2024). En entornos virtuales, estas dificultades se agravan si los estudiantes no regulan sus emociones o no se sienten cómodos pidiendo ayuda, lo que limita la efectividad del aprendizaje colaborativo (Ugulino & Ferreira Pires, 2021; Arakawa et al., 2021).

El acceso estratégico a recursos externos permitió que los estudiantes personalizaran su aprendizaje mediante la búsqueda activa de soluciones en tutoriales, foros, blogs técnicos o replays para revisar conceptos estudiados, rectificar errores y profundizar en temas específicos (Cheng, 2021; Xie et al., 2023). Pese a su valor, algunos estudios indican que las herramientas pueden no estar siendo utilizadas de manera efectiva, ya que, en algunas ocasiones, los estudiantes no hacen uso estratégico de las funcionalidades que se ponen a su disposición o sienten confusión por la falta de instrucciones claras para su uso, lo que limita su utilidad (Domino, 2024; Torres et al., 2024). Además, depender demasiado de recursos externos o de herramientas como la inteligencia artificial puede dificultar el desarrollo de habilidades metacognitivas. Esto es especialmente cierto si los estudiantes no han aprendido a hacer reflexiones críticas (Margulieux et al., 2024; Soares et al., 2023). Por otro lado, algunos autores señalan que el uso de este tipo de recursos puede volverse superficial, ya que



muchos estudiantes lo emplean solo para obtener respuestas rápidas sin comprender el código (Lee & Choi, 2023).

La estrategia de gestión del tiempo y del entorno de estudio también influyó directamente en la concentración y cumplimiento autorregulado de las tareas de los estudiantes. Soares et al. (2023), Prather et al. (2022), Zhu et al. (2024), Ugulino & Ferreira Pires (2021) y Tsai et al., (2024) señalaron que la implementación de rutinas de estudio, la definición de prioridades, las planificaciones regulares y la creación de ambientes propicios para el estudio tendían a producir más autodisciplina, mejorar el rendimiento y prevenir la procrastinación. Pero, para algunos estudiantes, estas prácticas las perciben como una carga extra o una exigencia difícil de sostener (Magana et al., 2024). Además, se ha identificado que, en los trabajos en grupo, los estudiantes, pocas veces aplican estrategias de control de tiempo, lo que dificulta la coordinación y afecta el resultado del trabajo colaborativo (Ferreira & Campos, 2023).

La autoeficacia y la motivación fueron consideradas factores determinantes en la persistencia y el éxito en el aprendizaje autorregulado de la programación (Öztürk, 2022 y Menon, 2021). Peteranetz et al. (2021) y Cheng et al. (2024) resaltan que la concentración del aprendizaje en objetivos personales tiene el efecto de incrementar la motivación intrínseca y la conexión emocional, y la motivación a partir de retos y reconocimientos con estrategias como rankings o recompensas simbólicas fomentan el compromiso sostenido (Abdirahman et al., 2023; Soares et al., 2023). No obstante, mantener la motivación a lo largo del curso no siempre es sencillo; algunos estudiantes inician con alto entusiasmo, pero progresivamente este se va desvaneciendo, especialmente cuando perciben las tareas como poco útiles, no saben cómo estudiar de forma efectiva o se sienten frustrados por la falta de resultados (Peteranetz et al., 2021; Torres et al., 2024). Además, algunos estudiantes dependen de la motivación extrínseca (logro académico o desarrollo profesional) y, cuando esta falta, la autorregulación puede verse comprometida (Zhu et al., 2024).

Diferentes investigaciones como las de Leite & Silveira (2024), Dayimani & Padayachee (2023), Majere & Bailey (2025) y Han & Ellis (2023) resaltan la capacidad de las plataformas como las LMS, GitHub o Discord para promover la autorregulación del aprendizaje. Esto se debe a que permiten el acceso autónomo a materiales, el trabajo colaborativo a distancia y reflexionar sobre la práctica personal. Empero, no todos los estudiantes hacen un uso activo de estos recursos de apoyo; algunos evitan pedir ayuda incluso cuando la necesitan o no utilizan los materiales disponibles, ya sea por falta de orientación o porque no los consideran relevantes (Arakawa et al., 2021; Domino, 2024; Peteranetz et al., 2021). Además, ante tareas complejas o que suponen una alta carga cognitiva, pueden sentirse sobrecargados y no saben cómo usar los recursos de manera efectiva (Shin & Song, 2022; Laitinen et al., 2024).

Finalmente, los estudios de Sun et al. (2025) o Neumann et al. (2025) destacan el uso de herramientas como MoodleBot, GPT-4 o ChatGPT basados en inteligencia artificial como una estrategia emergente para que los estudiantes interactúen de forma autodirigida y obtengan una retroalimentación técnica, reforzando su autorregulación y motivación. Sin embargo, algunos autores advierten que una excesiva dependencia de estas tecnologías puede limitar el desarrollo de la autorregulación si no se promueve una revisión crítica del contenido generado por las mismas (Paludo & Montresor, 2024). Además, las respuestas aparentemente



correctas generadas por estos recursos pueden generar sobreconfianza, disminuyendo la capacidad del estudiante para monitorear su comprensión y evaluar críticamente las soluciones (Prasad & Sane, 2024).

5. CONCLUSIÓN

Este estudio tuvo como objetivo identificar las estrategias de autorregulación del aprendizaje que los estudiantes de Ciencias de la Computación aplican. El análisis mostró un cierto equilibrio entre estrategias de tipo cognitivo (35 %), metacognitivo (34 %) y de administración de recursos (31 %), destacando especialmente la resolución de problemas, la reflexión crítica, el control del aprendizaje, la cooperación y el uso de herramientas digitales.

Los autores recomiendan que los cursos de formación en áreas afines a Ciencias de la Computación integren de manera explícita estrategias de autorregulación del aprendizaje desde etapas iniciales de la carrera. Además, deben incluir una formación tanto de estudiantes como de docentes sobre la importancia de la metacognición y la autoeficacia para fomentar el desarrollo del pensamiento computacional autorreflexivo. En el campo tecnológico, se sugiere fortalecer la retroalimentación automatizada y los entornos interactivos, así como promover el uso crítico de la inteligencia artificial.

Dada la diversidad de las estrategias de autorregulación identificadas en los estudios y la variabilidad en su implementación, se reconoce que no todos los estudiantes aplican estas estrategias con la misma frecuencia o calidad. Algunos estudiantes con menor experiencia o habilidades autorregulatorias previas necesitarán más orientación para beneficiarse plenamente del modelo y hacer adaptaciones personalizadas.

Aunque se identificaron limitaciones en los estudios, como pequeñas muestras que imposibilitan la generalización, las investigaciones han generado la suficiente base como para poder orientar prácticas pedagógicas respecto a la autorregulación del aprendizaje en Ciencias de la Computación. Se recomienda que futuras investigaciones analicen el impacto en diferentes niveles y contextos educativos mediados por las nuevas tecnologías.

REFERENCIAS BIBLIOGRÁFICAS

- Abdirahman, A. A., Hashi, A. O., Elmi, M. A., Dahir, U. M., & Romo Rodriguez, O. E. (2023). Exploring the impact of gamification on self-directed learning: A study in an online learning environment. *International Journal of Engineering Trends and Technology*, 71(9), 129–137. <https://doi.org/10.14445/22315381/IJETT-V71I9P212>
- Arakawa, K., Hao, Q., Greer, T., Ding, L., Hundhausen, C. D., & Peterson, A. (2021). In situ identification of student self-regulated learning struggles in programming assignments. In *Proceedings of the 52nd ACM Technical Symposium on Computer Science Education (SIGCSE '21)* (pp. 467–473). ACM. <https://doi.org/10.1145/3408877.3432357>
- Chen, M.-S., & Hsu, T.-C. (2024). Effects of the self-regulated learning and motivation on learning achievements of the programming courses. *Proceedings of the 32nd International Conference on Computers in Education*. <https://doi.org/10.58459/icce.2024.4973>



- Cheng, G. (2021). The effects of self-regulated learning strategies on computer programming achievement in teacher education. *Frontiers in Education Technology*, 4(4), 37–58. <https://doi.org/10.22158/fet.v4n4p37>
- Cheng, G., Zou, D., Xie, H., & Wang, F. L. (2024). Exploring differences in self-regulated learning strategy use between high- and low-performing students in introductory programming: An analysis of eye-tracking and retrospective think-aloud data from program comprehension. *Computers & Education*, 208, 104948. <https://doi.org/10.1016/j.compedu.2023.104948>
- Coronado, P. (2025). Repositorio revisión sistemática. <https://docs.google.com/spreadsheets/d/1DOOdOSC33n340XI1EHZbdCykCwDt29sQG E03Fem73JY/edit?gid=1911937509#gid=1911937509>
- Cloude, E. B., Baker, R. S., & Pankiewicz, M. (2023, December). Measuring self-regulated learning processes in computer science education. En J. L. Shih et al. (Eds.), *Proceedings of the 31st International Conference on Computers in Education* (pp. 1–9). Asia-Pacific Society for Computers in Education. <https://www.researchgate.net/publication/375091233>
- Dayimani, S., & Padayachee, K. (2023). Technology-based strategies predicated on self-regulated learning in a flipped computer programming classroom. *Proceedings of the 22nd European Conference on e-Learning (ECEL 2023)*, 400–408.
- Domino, M. (2024). Self-regulated learning skills research in computer science: The state of the field [Doctoral dissertation, Virginia Polytechnic Institute and State University].
- Ferreira, D. J., & Campos, D. S. (2023). Investigating how introductory programming students apply regulation strategies. In *Proceedings of the 15th International Conference on Computer Supported Education (CSEDU 2023)* (pp. 463–473). <https://doi.org/10.5220/0011659000003470>
- Ferreira, D. J., Campos, D. S. de, & Gonçalves, A. C. (2024). A framework of contextualized social regulation strategies in introductory programming. *Proceedings of the 57th Hawaii International Conference on System Sciences*. <https://hdl.handle.net/10125/107000>
- Gao, Z., Erickson, B., Xu, Y., Lynch, C., Heckman, S., & Barnes, T. (2022). You asked, now what? Modeling students' help-seeking and coding actions from request to resolution. *Journal of Educational Data Mining*, 14(3), 109–131.
- Han, F., & Ellis, R. A. (2023). Self-reported and digital-trace measures of computer science students' self-regulated learning in blended course designs. *Education and Information Technologies*, 28, 13253–13268. <https://doi.org/10.1007/s10639-023-11698-5>
- Leite, P. T., & Silveira, I. F. (2024). A computational system to support learning self-regulation to measure knowledge acquisition by students of computer science-related courses. XIII Congresso Brasileiro de Informática na Educação (CBIE 2024), XXXV Simpósio Brasileiro de Informática na Educação (SBIE 2024), 101–114. <https://doi.org/10.5753/sbie.2024.242147>
- Lee, J., & Choi, H. (2023). Exploring the effects of self-regulated learning strategies on students' learning in programming education. *Computers & Education*, 205, 104857. <https://doi.org/10.1016/j.compedu.2023.104857>



- Lei, Y., Fu, X., Zhao, J., & Yi, B. (2024). The effect of ability grouping on students' computational thinking in shared regulation-supported collaborative programming. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-024-12838-1>
- Li, H., & Ma, B. (2025). Design of AI-powered tool for self-regulation support in programming education. In *CHI 2025 Workshop on Augmented Educators and AI*, Yokohama, Japón.
- Loksa, D., Margulieux, L., Becker, B. A., Craig, M., Denny, P., Pettit, R., & Prather, J. (2022). Metacognition and self-regulation in programming education: Theories and exemplars of use. *ACM Transactions on Computing Education*, 22(4), Article 39. <https://doi.org/10.1145/3487050>
- Luo, K. (2024). Navigating the code: A qualitative study of novice programmers' perceptions and utilization of automated feedback for self-regulated learning. *Education and Technology*, 1(2), 10 pp. <https://doi.org/10.1145/3674399.3674430>
- Majere, F., & Bailey, R. (2025). TVET computer programming students' self-directed learning development through active teaching-learning strategies. University of Johannesburg. <https://doi.org/10.21203/rs.3.rs-6259241/v1>
- Margulieux, L. E., Prather, J., Reeves, B. N., Becker, B. A., Cetin Uzun, G., Loksa, D., Leinonen, J., & Denny, P. (2024). Self-regulation, self-efficacy, and fear of failure interactions with how novices use LLMs to solve programming problems. *Proceedings of the 2024 Innovation and Technology in Computer Science Education V. 1 (ITiCSE 2024)*. <https://doi.org/10.1145/3649217.3653621>
- Marquès Puig, J. M., Daradoumis, T., Arguedas, M., & Calvet Liñan, L. (2022). Using a distributed systems laboratory to facilitate students' cognitive, metacognitive and critical thinking strategy use. *Journal of Computer Assisted Learning*, 38(1), 209–222. <https://doi.org/10.1111/jcal.12605>
- Menon, P. (2021). An investigation on student perceptions of self-regulated learning in an introductory computer programming course. *Information Systems Education Journal*, 19(6), 13–26.
- Nančovska Šerbec, I. (2023). The overview of computer science/computational thinking education research. University of Ljubljana.
- Neumann, A. T., Yin, Y., Sowe, S., Decker, S., & Jarke, M. (2025). An LLM-driven chatbot in higher education for databases and information systems. *IEEE Transactions on Education*, 68(1), 103–115. <https://doi.org/10.1109/TE.2024.3467912>
- Onah, D. F. O., Pang, E. L. L., & Sinclair, J. E. (2021). Investigating self-regulation in the context of a blended learning computing course. *International Journal of Information and Learning Technology*. <https://doi.org/10.1108/IJILT-04-2021-0059>
- Öztürk, M. (2022). The effect of self-regulated programming learning on undergraduate students' academic performance and motivation. *Interactive Technology and Smart Education*. <https://doi.org/10.1108/ITSE-04-2021-0074>
- Paludo, G., & Montresor, A. (2024). Fostering metacognitive skills in programming: Leveraging AI to reflect on code. *2nd International Workshop on Artificial Intelligence Systems in Education*. <https://www.researchgate.net/publication/385620293>



- Peteranetz, M. S., Soh, L.-K., Shell, D. F., & Flanigan, A. E. (2021). Motivation and self-regulated learning in computer science: Lessons learned from a multiyear program of classroom research. *IEEE Transactions on Education*. <https://doi.org/10.1109/TE.2021.3049721>
- Pintrich, P. R. (2000). The role of goal orientation in self-regulated learning. In M. Boekaerts, P. R. Pintrich, & M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 451–502). Academic Press.
- Prather, J., et al. (2022). Getting by with help from my friends: Group study in introductory programming understood as socially shared regulation. In *ICER 2022* (pp. 7–11). <https://doi.org/10.1145/3501385.3543970>
- Prasad, P., & Sane, A. (2024). A self-regulated learning framework using generative AI and its application in CS educational intervention design. In *SIGCSE 2024*. <https://doi.org/10.1145/3626252.3630828>
- Şen, Ş. (2023). Relations between preservice teachers' self-efficacy, computational thinking skills and metacognitive self-regulation. *European Journal of Psychology of Education*, 38, 1251–1269. <https://doi.org/10.1007/s10212-022-00651-8>
- Shin, Y., & Song, D. (2022). The effects of self-regulated learning support on learners' task performance and cognitive load in computer programming. *Journal of Educational Computing Research*, 60(6), 1490–1513. <https://doi.org/10.1177/07356331211052632>
- Silva, L., Mendes, A., Gomes, A., & Fortes, G. (2023). What learning strategies are used by programming students? A qualitative study grounded on the self-regulation of learning theory. *ACM Transactions on Computing Education*. <https://doi.org/10.1145/3635720>
- Soares, L., Gomes, A., & Mendes, A. J. (2023). Exploring the impact of self-regulation of learning support on programming performance and code development. *IEEE Frontiers in Education Conference*. <https://doi.org/10.1109/FIE58773.2023.10343321>
- Song, D., Hong, H., & Oh, E. Y. (2021). Applying computational analysis of novice learners' computer programming patterns to reveal self-regulated learning. *Computers in Human Behavior*, 120, 106746. <https://doi.org/10.1016/j.chb.2021.106746>
- Sun, D., et al. (2025). How self-regulated learning is affected by feedback based on large language models. *Electronics*, 14(194). <https://doi.org/10.3390/electronics14010194>
- Susilowati, D., et al. (2024). Do computational thinking and self-regulated learning affect computer programming problem solving skills? *Jurnal Kependidikan*, 10(3), 1145–1157.
- Rebollo, M. (2024). Percepción del alumnado de actividades de alto impacto en un primer curso de programación. En *Actas de las JENUI* (Vol. 9, pp. 207–214). Universitat Politècnica de València.
- Tsai, C.-W., et al. (2024). Integrating online meta-cognitive learning strategy and team regulation to develop students' programming skills. *Universal Access in the Information Society*, 23, 395–410. <https://doi.org/10.1007/s10209-022-00958-9>
- Ugulino, W., & Pires, L. F. (2021). The use of metacognition to develop self-regulated learning skills in students of a computer programming course. In *SEFI 2021 Annual Conference*, Technische Universität Berlin.
- Xie, B., et al. (2023). Developing novice programmers' self-regulation skills with code replays. In *ICER '23 V1*. <https://doi.org/10.1145/3568813.3600127>



- Watanabe, K., Matsuda, Y., Nakamura, Y., Arakawa, Y., & Ishimaru, S. (2025). TrackThinkDashboard: Understanding student self-regulated learning in programming study. *International Journal of Activity and Behavior Computing*, 2025(1), 1–17. <https://doi.org/10.60401/ijabc9>
- Wu, Y., Wei, X., Liu, M., & Qian, Y. (2024, July). Exploring the effects of automated feedback on students in introductory programming using self-regulated learning theory. En *Proceedings of the ACM Turing Award Celebration Conference 2024 (ACM-TURC '24)* (pp. 76–80).
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory into Practice*, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2
- Zhu, M., Berri, S., Huang, Y., & Masoud, S. (2024). Computer science and engineering students' self-directed learning strategies and satisfaction with online learning. *Computers and Education Open*, 6, 100168. <https://doi.org/10.1016/j.cao.2024.100168>

Conflicto de Intereses: Los autores declaran que no tienen conflictos de intereses relacionados con este estudio y que todos los procedimientos seguidos cumplen con los estándares éticos establecidos por la revista. Asimismo, confirman que este trabajo es inédito y no ha sido publicado, ni parcial ni totalmente, en ninguna otra publicación.