



Ciencia Latina
Internacional

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), enero-febrero 2024,
Volumen 8, Número 1.

https://doi.org/10.37811/cl_rcm.v8i1

DETECCIÓN AUTOMÁTICA DE ESTILOS DE APRENDIZAJE USANDO INTERNET DE LAS COSAS

**AUTOMATIC DETECTION OF LEARNING STYLES USING
THE INTERNET OF THINGS**

Efrain Toledo Cubillos
Universidad Santiago de Cali

DOI: https://doi.org/10.37811/cl_rcm.v8i1.9869

Detección Automática de Estilos de Aprendizaje Usando Internet de las Cosas

Efrain Toledo Cubillos¹Efrain.toledo00@usc.edu.co<https://orcid.org/0000-0002-8036-0350>Universidad Santiago de Cali
Colombia

RESUMEN

La incorporación de la tecnología como una herramienta de gestión del conocimiento y apoyo a las prácticas pedagógicas en el aula, en conjunción con estándares de calidad, tiene el potencial de crear experiencias de aprendizaje ubicuas de gran impacto en la formación académica. Además, el avance de tecnologías abre nuevas posibilidades para la innovación mediante el monitoreo en tiempo real del comportamiento y la interacción de los estudiantes en su entorno educativo, lo que facilita la adaptación de las estrategias didácticas a las necesidades individuales de cada estudiante. El propósito de esta investigación es evaluar el diagnóstico de estilos de aprendizaje utilizando el modelo de Felder-Silverman en combinación con tecnologías de detección automática y el internet de las cosas. Para llevar a cabo esta investigación, se seleccionó una muestra de 24 estudiantes de educación media. El enfoque de la investigación es cuantitativo, y se adoptó un diseño no experimental transaccional. Los resultados indican que el uso de tecnología para la detección de estilos de aprendizaje ofrece ventajas significativas en comparación con el método tradicional.

Palabras clave: estilo de aprendizaje, modelos de estilo de aprendizaje, tecnología educativa

¹ Autor Principal

Correspondencia: efrain.toledo00@usc.edu.co

Automatic detection of learning styles using the internet of things

ABSTRACT

The incorporation of technology as a tool for knowledge management and support for pedagogical practices in the classroom, in conjunction with quality standards, has the potential to create ubiquitous learning experiences with great impact on academic training. Furthermore, the advancement of technologies opens new possibilities for innovation through real-time monitoring of the behavior and interaction of students in their educational environment, which facilitates the adaptation of teaching strategies to the individual needs of each student. The purpose of this research is to evaluate the diagnosis of learning styles using the Felder-Silverman model in combination with automatic detection technologies and the Internet of Things. To carry out this research, a sample of 24 high school students was selected. The research approach is quantitative, and a transactional non-experimental design was adopted. The results indicate that the use of technology to detect learning styles offers significant advantages compared to the traditional method.

Keywords: learning style, learning styles models, educational technology

Artículo recibido 16 enero 2024

Aceptado para publicación: 23 febrero 2024



INTRODUCCIÓN

A partir de las características intrínsecas y las experiencias en diversos contextos, los estudiantes desarrollan una variedad de niveles de motivación, preferencias, actitudes, estilos de aprendizaje y respuestas ante el proceso de formación. Según Wooldridge (1995), el concepto de estilo de aprendizaje se refiere a los patrones cognitivos, emocionales y psicológicos que actúan como indicadores relativamente constantes de cómo los estudiantes perciben, interactúan y reaccionan en el entorno de aprendizaje. Por otro lado, los estilos de enseñanza engloban más que solo un método instructivo, ya que incluyen aspectos personales, preocupaciones individuales y creencias sobre los procesos académicos (Ventura, 2016). A partir de esto, se puede inferir que los educadores que comprenden los estilos de aprendizaje de sus estudiantes están mejor preparados para tomar decisiones informadas respecto al contenido, diseño y métodos de enseñanza, con el propósito de ampliar las oportunidades de aprendizaje efectivo (Guzmán-Camacho y Mendoza González, 2023).

Por lo tanto, resulta esencial la identificación y personalización de las preferencias de aprendizaje de los estudiantes mediante un enfoque que permita el diagnóstico basado en la recopilación de datos relacionados con el comportamiento del alumno. Entre los diversos modelos disponibles, destaca el desarrollado por Felder y Silverman, que tiene la capacidad de analizar las características de aprendizaje en función de cómo los estudiantes asimilan, procesan y transforman la información en el contexto del proceso de aprendizaje, a través de sus experiencias y su interacción con todos los elementos de su entorno. Según Feldman (2015), en la actualidad, existe una tendencia creciente hacia la adopción del Modelo de Estilo de Aprendizaje de Felder-Silverman (FSLSM) o modelos personalizados que se adaptan de manera más efectiva a los sistemas educativos que hacen uso de la tecnología. Además, otros académicos, como Özpolat y Akar (2009), sostienen que el modelo FSLSM es uno de los más prevalentes en la actualidad, especialmente adecuado para aplicaciones que abarcan temas de ciencia básica y resulta idóneo para sistemas educativos adaptativos.

Además, para llevar a cabo el diseño de instrucción y la implementación de las teorías cognitivas en sistemas de aprendizaje en línea y ubicuo, es esencial la identificación en tiempo real de los estilos de aprendizaje. Esto resulta fundamental tanto para aprovechar los enfoques actuales como para desarrollar nuevos principios orientados al diseño de materiales educativos basados en multimedia y su

aplicabilidad en los medios emergentes y las tecnologías de instrucción, como la realidad virtual (RV), la inteligencia artificial (IA), el internet de las cosas (IoT) y otros (Mayer, 2017). En el contexto de la Teoría Cognitiva de Aprendizaje Multimedia, que se enfoca en el modelo cognitivo de procesamiento de la información, Mayer argumenta que el diseño de materiales de aprendizaje multimedia debe estar en sintonía con la forma en que las personas procesan la información.

Por lo tanto, el propósito de este artículo radica en comparar el empleo de cuestionarios, un método convencional, con enfoques automatizados que hacen uso de Internet de las Cosas (IoT) y la inteligencia artificial (IA) para identificar los estilos de aprendizaje según el modelo de Felder y Silverman. Este estudio se enfoca en un grupo de 24 estudiantes de educación secundaria, cuyas edades oscilan entre los 15 y los 18 años, y que están matriculados en la asignatura de tecnología e informática. El análisis se centra en las competencias de pensamiento computacional, incluyendo el pensamiento algorítmico, la descomposición, el reconocimiento de patrones, la abstracción, la depuración y el pensamiento lógico.

Modelo de Estilo de Aprendizaje de Felder y Silverman

El modelo FSLSM postula que las personas presentan preferencias en cinco dimensiones continuas y bipolares distintas. Estas dimensiones incluyen: 1) La forma en que comprenden la información, que abarca el estilo global y el secuencial. 2) Cómo los estudiantes reciben u obtienen la información, que engloba a los estudiantes visuales y a los auditivos o verbales. 3) El canal sensorial preferido para la percepción de la información, que se divide en el estilo de aprendizaje sensitivo y el intuitivo. 4) El procesamiento de la información, que se distingue entre los activos y los reflexivos. 5) Las preferencias en la organización de la información, que comprenden a los intuitivos y los deductivos. En resumen, En la Tabla 1, se presentan las cinco dimensiones, las cuales generan un total de 32 estilos de aprendizaje, según lo propuesto por (Tocci, 2015).

Tabla 1 Sistema conceptual de estilos de aprendizaje y de enseñanza

Estilos de aprendizaje		Estilos de enseñanza	
Sensorial	Percepción	Concreto	Tipos de contenido
Intuitivo		Abstracto	
Activo	Procesamiento	Activo	Participación de los estudiantes
Reflexivo		Pasivo	
Visual	Representación	Visual	Presentación de contenidos
Verbal		Verbal	
Secuencial	Comprensión	Secuencial	Perspectiva
Global		Global	

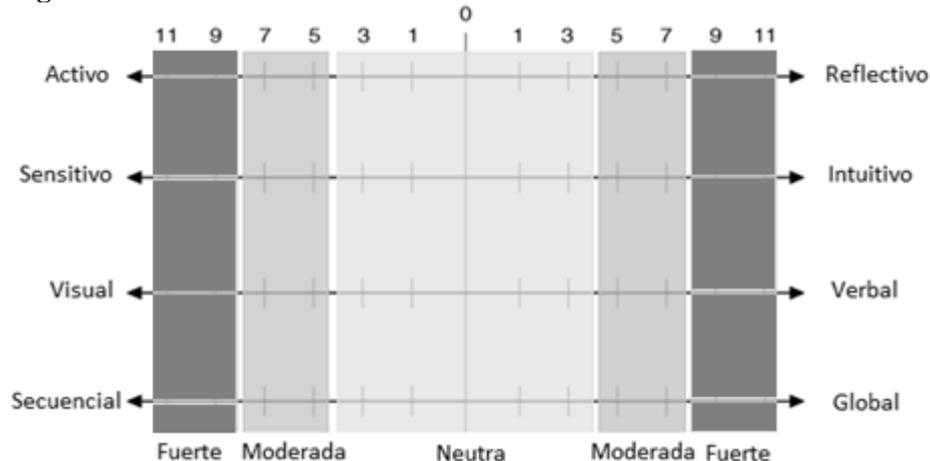
Nota. Tomado de Ventura (2016)

En 1991, Richard Felder y Barbara Silverman presentaron el Índice de Estilo de Aprendizaje (ILSQ), una herramienta psicométrica diseñada para evaluar los estilos de aprendizaje. La Figura 1 muestra las métricas de este instrumento en cuatro de las cinco dimensiones del modelo, omitiendo la dimensión de organización de la información (Intuitivo/Deductivo). Esta omisión se justifica por el enfoque del modelo en estudiantes de ingeniería, ya que investigaciones previas revelaron que la mayoría de estos estudiantes tienden hacia enfoques inductivos (Felder y Silverman, 1988).

Sin embargo, (Ventura, 2016) argumenta que la eliminación de la dimensión de organización se debió a que esta no se alineaba con una descripción neutral de las acciones en el aula, lo que era incompatible con la naturaleza conceptual del término "estilo". En resumen, el instrumento evalúa 16 de los 32 estilos de aprendizaje propuestos por el modelo, excluyendo la dimensión de organización de la información. Un aspecto relevante que respalda la elección de este modelo son los estudios de confiabilidad y validez del instrumento realizados por Felder y Spurlin (2005).

El Índice de Estilo de Aprendizaje (ILS) comprende un total de 44 ítems, distribuidos en once preguntas por cada una de las cuatro dimensiones evaluadas. Este cuestionario coloca al individuo en un punto específico dentro de las métricas de cada dimensión y luego divide las preferencias de aprendizaje en tres categorías: preferencia fuerte (cuando los valores numéricos oscilan entre 9 y 11), preferencia moderada (en el rango de 5 a 7) y preferencia leve (cuando el estudiante muestra un equilibrio en la dimensión, con valores en la escala de 1 a 3).

Figura 1. Métricas del instrumento ILS de Felder – Silverman



Nota. Adaptado de Felder y Silverman (1988).

En situaciones de equilibrio, donde el estudiante presenta preferencias en ambos extremos del espectro, la identificación de su estilo de aprendizaje se vuelve más desafiante. En contraste, a medida que el estudiante se aleja del punto central, es más probable que desarrolle una preferencia moderada o fuerte por un estilo de aprendizaje en esa dimensión, lo que simplifica su caracterización.

Como plantea Ventura (2016), la detección de los estilos de aprendizaje se vuelve más detallada al considerar valores fuertes, moderados y neutros para cada dimensión. Por ejemplo, un estudiante con una preferencia fuerte por la dimensión activa (valores de 9 a 11) exhibe todas las características típicas de un aprendiz activo. Por otro lado, un estudiante con una preferencia moderada por esta dimensión (valores de 5 a 7) muestra la mayoría de las características de un estudiante activo, aunque no todas. En el caso de un estudiante con una preferencia leve o neutral (valores de 1 a 3), este exhibe cantidades similares de características activas y reflexivas, lo que dificulta su clasificación como estrictamente activo o reflexivo. En este artículo, se examinan las dimensiones de comprensión de la información a través de sus dos estilos, Secuencial y Global, en el contexto del diseño de la práctica educativa. Además, se aborda la dimensión vinculada a la percepción de la información, considerando sus dos estilos, Sensitivo e Intuitivo.

Dimensión de Comprensión de la Información. Esta dimensión se relaciona con el desarrollo de la comprensión de la información a través de los siguientes estilos de aprendizaje: 1) Global: los estudiantes con un enfoque global emplean un pensamiento divergente y tienden a ver la información en un contexto general. Les resulta más sencillo aprender al obtener una visión panorámica de los

contenidos desde el principio, sin necesariamente establecer un orden específico de los temas. Sin embargo, a veces pueden experimentar dificultades al tratar de comprender información de manera parcial o fragmentada. 2) Secuencial: por otro lado, los estudiantes de enfoque secuencial siguen procesos de razonamiento lineal al abordar problemas. Siguen un orden secuencial en la asimilación de la información y pueden trabajar con el material incluso cuando su comprensión es parcial o superficial.

Dimensión según la Percepción de la Información. Esta dimensión se encarga de categorizar las preferencias relacionadas con la percepción de la información, y dentro de ella se identifican dos estilos de aprendizaje distintos: 1) Sensitivos: según el modelo de Felder y Silverman, los estudiantes con inclinaciones sensitivas tienden a recopilar datos a través de sus sentidos. Tienen una preferencia por la experimentación y valoran la información detallada. Suelen abordar problemas utilizando métodos conocidos y tienen una afinidad por memorizar hechos y cuidar los detalles. 2) Intuitivos: en contraste, los estudiantes intuitivos muestran menos interés en los detalles minuciosos y prefieren utilizar la especulación, la imaginación y las corazonadas al abordar situaciones. Se sienten atraídos por la innovación y no disfrutan tanto de la repetición. Optan por principios y teorías en lugar de centrarse en datos concretos. Una de sus fortalezas es su habilidad para comprender rápidamente nuevos conceptos, aunque a veces pueden pasar por alto detalles importantes. La identificación de esta dimensión se puede llevar a cabo mediante la observación de diferencias en el número de intentos y la precisión en secciones de cuestionarios o pruebas realizadas en dispositivos programables.

Enfoques para el Diagnóstico de Estilos de Aprendizaje

Dentro del proceso de diagnóstico de estilos de aprendizaje, se pueden distinguir dos enfoques principales: el enfoque convencional y el enfoque automático. A su vez, según Wibirama et al. (2020), el enfoque automático se subdivide en dos clasificaciones adicionales. El primer enfoque se basa en el uso de metodologías inteligentes, como la inteligencia artificial, para analizar los datos relacionados con el comportamiento del estudiante en su entorno de aprendizaje. Por otro lado, el segundo enfoque utiliza sensores y reglas de inferencia directa. Por otro lado, Feldman et al. (2015) identifican dos técnicas específicas para llevar a cabo la detección automática del estilo de aprendizaje: una se basa en el análisis de datos y la otra se apoya en la revisión de la literatura.

Técnica Tradicional



Se parte del supuesto de que los estilos de aprendizaje permanecen estables a lo largo de un período prolongado. Como resultado, la aplicación de métodos convencionales, como cuestionarios, evaluaciones de comportamiento y entrevistas, tiene como consecuencia la incapacidad de capturar las fluctuaciones temporales en los procesos cognitivos de manera efectiva, según señala Wibirama et al. (2020). Además, los estudiantes pueden mostrar falta de interés al enfrentarse a cuestionarios con un alto número de preguntas, lo que los lleva a seleccionar respuestas al azar o a responderlas bajo la suposición de que existen respuestas correctas e incorrectas. Asimismo, la falta de conocimiento acerca de sus propios estilos de aprendizaje puede llevarlos a dar respuestas inexactas en relación con sus preferencias de aprendizaje, como menciona Feldman et al. (2015).

Técnicas de detección automática del estilo de aprendizaje

En el desarrollo de un sistema de aprendizaje adaptativo destinado a brindar una experiencia personalizada, resulta esencial emplear estrategias automáticas para registrar los patrones de comportamiento a través de la interacción en el mismo entorno educativo, como apuntan Karagiannis et al. (2018). Esto conlleva varias ventajas significativas: en primer lugar, no se necesita un esfuerzo adicional para recopilar la información; en segundo lugar, se obtienen datos en tiempo real basados en experiencias auténticas; y, por último, se permite a los estudiantes enfocarse en su proceso de aprendizaje en lugar de dedicar tiempo a completar cuestionarios, tal como destacan Feldman et al. (2015).

Existen diversos factores que influyen en los enfoques empleados para la detección automatizada de estilos de aprendizaje: los atributos considerados, que abarcan aspectos como la personalidad o el comportamiento del estudiante; El tipo de técnica utilizada, que puede comprender desde redes bayesianas y árboles de decisión hasta algoritmos genéticos y redes neuronales artificiales, entre otros; La infraestructura empleada, que involucra sistemas de gestión del aprendizaje, interfaces de usuario especializadas, y entornos de aprendizaje ubicuos, por mencionar algunos ejemplos (Özpolat y Akar, 2009). Estos factores desempeñan un papel crucial en la determinación de la metodología adecuada para la detección automatizada de estilos de aprendizaje.

El primer paso para determinar el estilo de aprendizaje implica establecer una correlación entre el comportamiento de los estudiantes y factores medibles que reflejen diversas variables analíticas

relacionadas con el proceso de aprendizaje. Además, esta correlación debe considerar diferentes dimensiones observables que se ajusten a las características específicas del entorno educativo en cuestión. Por lo tanto, comprender a fondo el contexto en el que se desarrollan las prácticas pedagógicas es esencial para identificar cómo medir estas variables de manera efectiva.

Para seguir de cerca el comportamiento de los estudiantes, resulta esencial transformar la información en un conjunto de variables que sean rastreables según el entorno de aprendizaje específico. Como se presenta en la Tabla 2, de acuerdo con Essa et al. (2023), existen cuatro tipos de variables que se pueden monitorear.

Tabla 2 Tipos de variables para la medición automática de estilos de aprendizaje.

Tipo de Variable	Forma de Medición
Conocimiento	Resultados de exámenes Resultados discriminados por tipo de pregunta
Cronométrico	Tiempo dedicado a realizar el examen Tiempo dedicado a cada objeto de aprendizaje
Intentos	Número de ejercicios realizados Número de ejemplos leídos Número de visitas de contenido textual (web) Numero de clics
Navegación	Participación en foros, chat y sistemas de correo, contenido omitido

Nota. Adaptado de Essa et al. (2023)

Una ventaja adicional del análisis dinámico del comportamiento de los estudiantes es la capacidad para registrar los cambios en sus preferencias de aprendizaje a lo largo del tiempo, lo que proporciona metadatos valiosos para evaluar las estrategias didácticas que podrían mejorar los estilos de aprendizaje menos sólidos. A continuación, se describen dos enfoques para la detección automática: la técnica basada en la revisión de la literatura y la técnica basada en datos.

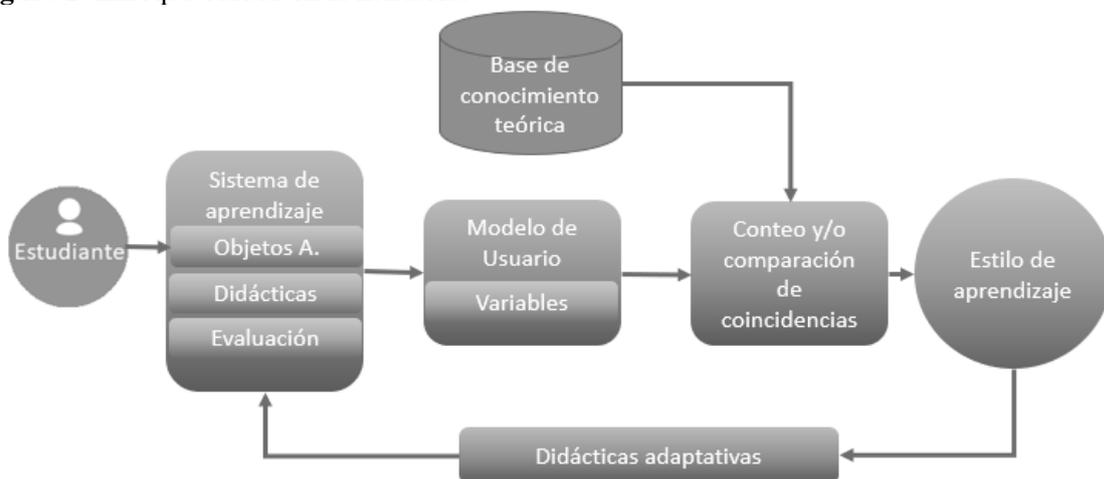
Técnica Basada en la Literatura

El método basado en la literatura implica la comparación del comportamiento de los estudiantes en el contexto académico con lo que se describe en las fuentes teóricas relevantes, con el propósito de identificar similitudes con respecto a sus estilos de aprendizaje. Luego, se aplican reglas de inferencia que toman en cuenta el número de coincidencias entre el comportamiento observado y las características teóricas de cada estilo de aprendizaje. La finalidad de este enfoque es desarrollar un clasificador tecnológico capaz de identificar los comportamientos que se asocian, según la literatura, con cada estilo de aprendizaje del modelo.

Una de las ventajas destacadas de este método radica en que no requiere algoritmos de clasificación, ya que se basa en reglas que cuentan las variables observables que concuerdan con los comportamientos teóricos vinculados a cada estilo de aprendizaje. Por ejemplo, en el contexto de la dimensión de recepción de la información, se podría evaluar el tiempo que un estudiante dedica al análisis de objetos de aprendizaje visuales en comparación con el tiempo invertido en el estudio de material textual. Mediante métricas adecuadas, se determina si un estudiante muestra preferencia por el aprendizaje visual o verbal. Según (Dung y Florea, 2012), este enfoque ha demostrado tener un potencial notable en la identificación de estilos de aprendizaje, logrando precisión y automatización efectiva.

En la Figura 2, se ilustra el proceso de detección automática a través del enfoque basado en la literatura. En este proceso, se permite la interacción con diversos objetos de aprendizaje para medir variables relacionadas con el comportamiento y el desempeño del estudiante. Luego, se contrastan estos resultados con los comportamientos teóricos que son descritos por los modelos de estilos de aprendizaje, lo que facilita la identificación de las dimensiones de estilo de cada estudiante. Además, es posible emplear estrategias didácticas adaptativas para mejorar el proceso de aprendizaje y, al mismo tiempo, validar el estilo de aprendizaje específico de cada estudiante.

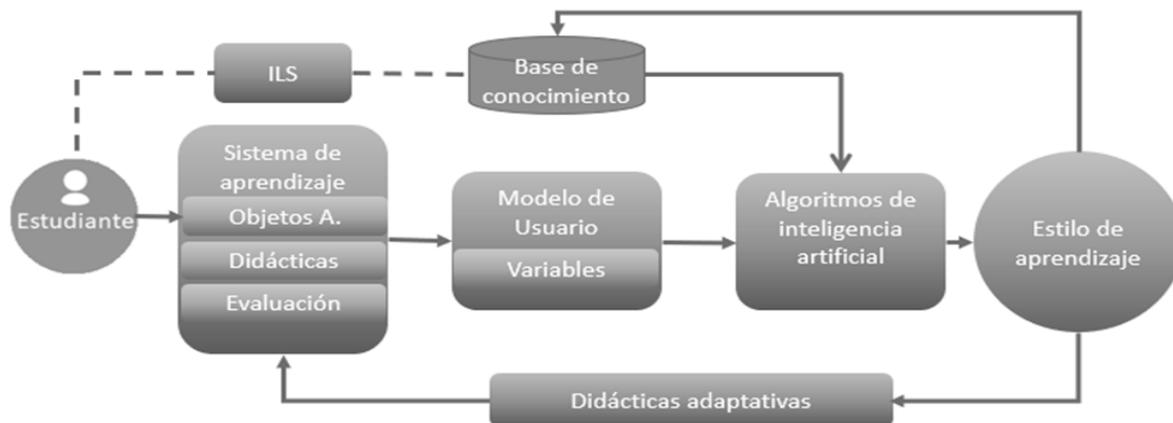
Figura 2. Enfoque basado en la literatura.



Técnica basada en los datos

Se utiliza tecnología que permite registrar el rendimiento de los estudiantes durante su proceso de aprendizaje, y estos datos se someten a un algoritmo de inteligencia artificial de clasificación, tal como se ilustra en la Figura 3. Este enfoque se destaca por su alta precisión, gracias al uso de datos reales procedentes de una amplia gama de recursos de aprendizaje diversos. Sin embargo, la precisión de este enfoque se ve fuertemente influenciada por la cantidad de datos disponibles en los entornos educativos.

Figura 3. Esquema centrado en los datos.



MATERIALES Y MÉTODO.

La investigación actual se adhiere a un enfoque cuantitativo en el que se llevará a cabo una comparación entre los resultados obtenidos a través del método convencional, que consiste en la administración del cuestionario del Índice de Estilo de Aprendizaje (ILS por sus siglas en inglés), y el método de detección automática basado en datos.

Se emplea el Índice de Estilo de Aprendizaje ILS como herramienta de investigación para identificar el estilo de aprendizaje en las dimensiones de percepción y comprensión, lo que permitirá categorizar a los estudiantes en grupos de sensitivos/intuitivos y secuenciales/globales. En cuanto a la evaluación de la confiabilidad del instrumento, es posible determinar su consistencia interna mediante el coeficiente alfa de Cronbach. Esta técnica resulta adecuada para evaluar la fiabilidad de un instrumento cuando se aplica en una sola ocasión. Los valores del coeficiente alfa de Cronbach pueden variar entre 0 y 1, donde valores cercanos o iguales a 0 indican una fiabilidad deficiente, mientras que valores cercanos o iguales a 1 indican una fiabilidad completa. Para obtener el valor del coeficiente alfa de Cronbach, se pueden emplear herramientas de análisis de datos especializadas.

La Tabla 3 proporciona detalles sobre los objetos de aprendizaje y las variables que se miden para cada estilo en un entorno de aprendizaje centrado en la enseñanza de la programación de computadoras. Este análisis considera dos situaciones pedagógicas que podrían surgir: el primer escenario involucra la utilización de kits de programación físicos disponibles en la institución educativa, mientras que el segundo escenario se refiere al uso de simuladores para la programación informática.

Tabla 3 Objetos de aprendizaje por cada dimensión y variables de aprendizaje.

Estilo de aprendizaje	Variables para el Kit de programación y uso del Internet de las Cosas	Variables para los Simuladores
Sensitivos	Tiempo de realizar ejercicios de programación con ejercicios prácticos (TEP).	Tiempo de simular códigos con ejercicios prácticos (TSP).
Inductivos	Tiempo de realizar ejercicios de programación que involucra conceptos (TEC).	Tiempo de simular códigos con información conceptual (TSC).
Secuencial	Tiempo de realizar ejercicios de programación con información detallada y paso a paso (TED).	Tiempo de simular códigos con información en pasos consecutivos (TSD).
Global	Tiempo de realizar ejercicios con información general (TEG).	Tiempo de simular códigos con ejercicios que involucra información general (TSG).

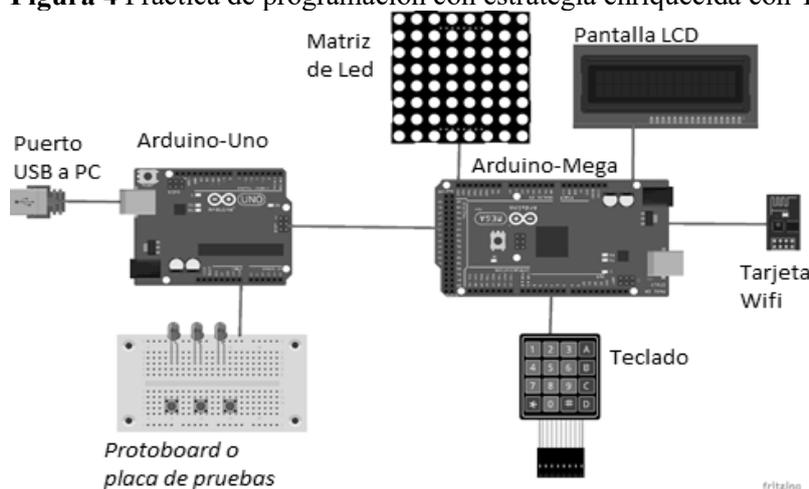
Nota: Adaptada de Dung y Florea (2012)

La Figura 4 ofrece una visión general del proyecto implementado mediante tarjetas Arduino. Este sistema ha sido diseñado para permitir la realización de diversos tipos de ejercicios, los cuales evalúan tanto la capacidad de resolución de problemas como las habilidades de programación de los estudiantes. El primer ejercicio involucra la resolución de dos laberintos, donde se presenta a los estudiantes un laberinto a través de una matriz de LEDs con tres colores distintos, y se les desafía a resolverlo. En este ejercicio, se registran variables como el tiempo empleado y el número de intentos necesarios para completar la actividad educativa. El segundo ejercicio se centra en medir el tiempo que los estudiantes requieren para programar la placa Arduino Uno con el objetivo de hacer que un LED parpadee en ocho ocasiones. Por último, el tercer ejercicio de programación consiste en cronometrar el tiempo que los

estudiantes emplean para programar el Arduino Uno de manera que, mediante el uso de un pulsador, un LED se encienda y apague alternadamente durante cuatro ciclos completos.

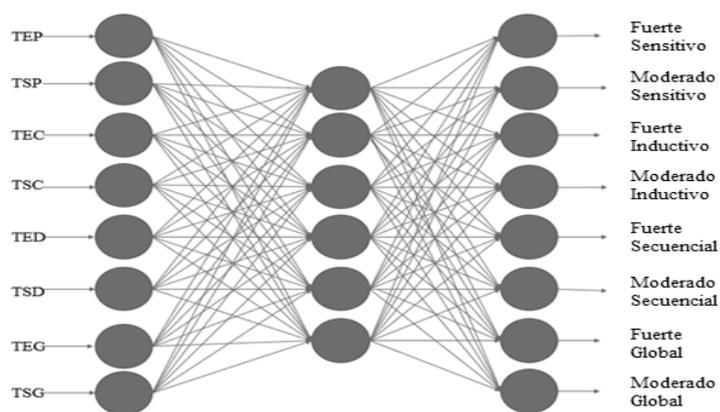
Los tiempos que los estudiantes dedican a completar sus prácticas de programación se registran en una base de datos, se someten a un proceso de normalización y luego se introducen en la capa de entrada de un algoritmo de Red Neuronal Artificial (RNA), como se representa en la Figura 5. El modelo de la Red Neuronal consta de tres capas: Capa de entrada con 8 neuronas, cada una correspondiente a las 8 variables presentadas en la Tabla 3; Una capa oculta encargada de procesar los datos; Y una capa de salida con seis neuronas que representan los estilos de aprendizaje de las dos dimensiones: Sensitivo/Inductivo y Secuencial/Global. Si ninguna neurona en la capa de salida se activa, esto indica que el estudiante presenta un estilo de aprendizaje neutral o equilibrado en esa dimensión.

Figura 4 Practica de programación con estrategia enriquecida con TIC.



La estructura de la red neuronal utilizada es una red neuronal feedforward (FFNN), lo que significa que la información fluye en una sola dirección, desde las capas de entrada hacia las capas de salida, sin ciclos o retroalimentación. La función de activación empleada en los nodos de la red es la función sigmoide. En esta estructura específica, todas las neuronas en cada capa están conectadas con todas las neuronas en la capa anterior, lo que se conoce como una conexión completamente interconectada. Los nodos de entrada proporcionan información a las unidades en la capa oculta, y luego las salidas de la capa oculta se transmiten a la capa de salida.

Figura 5 Red Neuronal Artificial tipo feedforward para calcular Estilo de Aprendizaje.



RESULTADOS Y DISCUSIÓN

En primer lugar, se emplea el Cuestionario ILS para evaluar y caracterizar el estilo de aprendizaje de los 24 estudiantes que conforman el grupo experimental, utilizando el modelo propuesto por Felder y Silverman. Luego, con base en los resultados obtenidos, se procede a entrenar una red neuronal para la detección automática de estos estilos. En la Tabla 4 se resumen los resultados individuales de los estudiantes en las dimensiones de estilo secuencial-global y sensitivo-intuitivo.

Tabla 4 Resultados del cuestionario ILS de estilo de aprendizajes

Id Estudiante	Secuencial-Global	Sensitivo-Intuitivo
1	Equilibrado	Moderado Intuitivo
2	Equilibrado	Moderado Sensitivo
3	Equilibrado	Equilibrado
4	Equilibrado	Moderado Sensitivo
5	Moderado Secuencial	Fuerte Intuitivo
6	Equilibrado	Equilibrado
7	Equilibrado	Equilibrado
8	Moderado global	Moderado Intuitivo
9	Moderado Secuencial	Moderado Sensitivo
10	Equilibrado	Equilibrado
11	Equilibrado	Moderado Sensitivo
12	Moderado global	Moderado Intuitivo
13	Equilibrado	Equilibrado
14	Moderado global	Moderado Sensitivo
15	Moderado global	Moderado Intuitivo
16	Equilibrado	Fuerte Sensitivo

17	Moderado global	Equilibrado
18	Equilibrado	Fuerte Intuitivo
19	Equilibrado	Moderado Sensitivo
20	Fuerte Secuencial	Fuerte Intuitivo
21	Equilibrado	Equilibrado
22	Equilibrado	Moderado Sensitivo
23	Equilibrado	Equilibrado
24	Equilibrado	Fuerte Intuitivo

En relación a la dimensión Secuencial/Global, en términos generales, el 66.66% (16) de la muestra presenta un equilibrio entre ambos estilos. Además, se observa que un 12.5% (3) exhibe un nivel moderado de estilo Global, otro 12.5% (3) muestra un nivel moderado de estilo Secuencial, y un 8.33% presenta un estilo fuertemente secuencial.

En cuanto a los resultados relacionados a la dimensión de la percepción de la información se observa que un 12.5% (3) de los participantes presentan un perfil fuertemente sensitivo, un 29.16% (7) muestran un nivel moderado de sensibilidad, un 25% (6) se ubican en un equilibrio entre ambos extremos, un 16.66% (4) exhiben un nivel moderado de intuición, y otro 16.66% (4) muestran un perfil fuertemente intuitivo.

Posteriormente, lleva a cabo la recolección de los atributos de aprendizaje utilizando la tecnología de Internet de las Cosas. Los datos de las variables que alimentan la red neuronal artificial se registran en una base de datos MySQL a través de una interfaz web, la cual es administrada y gestionada mediante la herramienta de código abierto phpMyAdmin. Los resultados se presentan en la Tabla 5, Las celdas resaltadas muestran discrepancias en el estilo de aprendizaje en comparación con la evaluación realizada a través del cuestionario ILS. En concreto, la dimensión Secuencial-Global presenta una discrepancia del 20,83%. Pero, la dimensión que muestra mayor diferencia entre el método tradicional y el método automático es la dimensión Sensitivo-Inductivo, con un porcentaje del 33,33%.

Tabla 5 Resultados de los estilos de aprendizaje utilizando detección automática

Id	Secuencial-Global	Sensitivo-Intuitivo
Estudiante		
1	Equilibrado	Equilibrado
2	Moderado Secuencial	Moderado Sensitivo
3	Equilibrado	Equilibrado
4	Equilibrado	Fuerte Sensitivo
5	Moderado Secuencial	Moderado Intuitivo
6	Equilibrado	Equilibrado
7	Moderado global	Moderado Intuitivo
8	Equilibrado	Moderado Intuitivo
9	Moderado Secuencial	Moderado Sensitivo
10	Equilibrado	Equilibrado
11	Equilibrado	Moderado Sensitivo
12	Moderado global	Fuerte Intuitivo
13	Equilibrado	Equilibrado
14	Moderado Global	Moderado Sensitivo
15	Moderado global	Equilibrado
16	Equilibrado	Fuerte Sensitivo
17	Moderado global	Equilibrado
18	Equilibrado	Equilibrado
19	Moderado Global	Moderado Sensitivo
20	Equilibrado	Fuerte Intuitivo
21	Equilibrado	Equilibrado
22	Equilibrado	Fuerte Intuitivo
23	Equilibrado	Equilibrado
24	Equilibrado	Fuerte Intuitivo

Nota. Los estilos sombreados son los que cambiaron después de realizar la práctica pedagógica con el uso del EIA.

En la tabla 6, se aprecia, en forma general que la mayoría de los estilos de aprendizaje que cambiaron con relación al método tradicional, lo hicieron en un nivel, mientras que 2 de esos cambios lo hicieron en dos niveles y un solo estudiante presento un cambio de tres niveles pasando de moderado sensitivo a fuertemente intuitivo.

Tabla 6 Diferencia resultados con ILQ frente a detección automática

Id Estudiante	Secuencial-Global	Sensitivo-Intuitivo
1	---	1 nivel
2	1 nivel	---
4	---	1 nivel
5	---	1 nivel
7	1 nivel	1 nivel
8	1 nivel	---
12	---	1 nivel
15	---	1 nivel
18	---	2 niveles
19	1 nivel	---
20	2 nivel	---
22	---	3 niveles

Nota. Los estilos sombreados son los que cambiaron después de realizar la práctica pedagógica con el uso del EIA.

Por último, e seleccionaron los estudiantes que presentaron diferencias entre el método tradicional y la detección automática, en esta ocasión se les realizó el cuestionario seleccionando solamente 11 de las preguntas o ítems referentes al estilo en discrepancia de cada estudiante. Al comparar los nuevos resultados se presentan en la tabla 7.

Tabla 7 Diferencia resultados con ILQ recortado frente a detección automática

Id Estudiante	Secuencial-Global	Sensitivo-Intuitivo
1	--	Equilibrado
2	Moderado Secuencial	--
4	--	Moderado Sensitivo
5	Moderado Secuencial	Moderado Intuitivo
7	Moderado global	Equilibrado
8	Moderado Secuencial	--
12	--	Fuerte Intuitivo
15	--	Moderado Intuitivo
18	--	Equilibrado
19	Moderado Global	--
20	Moderado Secuencial	--
22	--	Fuerte Intuitivo

Nota. Los estilos sombreados son los que cambiaron con relación a los resultados mediante el método automático.

Los resultados presentados en la Tabla 7 indican que se produjeron cambios en el 8.33% (2 de 24) de los casos en la dimensión Secuencial-Global y en el 12.5% (3 de 24) en la dimensión Sensitivo-Intuitivo con relación a los resultados de la detección automática. Estos resultados sugieren que la detección automática de estilos de aprendizaje aborda de manera efectiva los desafíos asociados con los métodos basados en cuestionarios, los cuales a menudo pueden generar falta de motivación, respuestas aleatorias debido al cansancio, desinterés y la falta de conocimiento de los estudiantes sobre sus propias preferencias de aprendizaje.

CONCLUSIONES

En el ámbito de la detección automática de estilos de aprendizaje, uno de los modelos más ampliamente utilizados es el desarrollado por Felder y Silverman, y su popularidad se debe a su robustez en términos de validez y consistencia interna cuando se aplica en diversos entornos educativos. Este enfoque también reconoce la variabilidad de los estilos de aprendizaje a lo largo del tiempo, influenciada por factores como el contexto, los conocimientos previos y las estrategias didácticas empleadas por los educadores. Debido a estas consideraciones, este modelo proporciona una base sólida para comparar y evaluar los estilos de aprendizaje, lo que ha sido ampliamente respaldado en la literatura. Además, este enfoque permite clasificar los estilos de aprendizaje en categorías que van desde leve hasta fuerte, lo que, a su vez, facilita la realización de recomendaciones personalizadas en las prácticas pedagógicas, teniendo en cuenta las combinaciones específicas de estilos de aprendizaje (Fedel et al., 2015).

La detección automática de estilos de aprendizaje se plantea como una solución para abordar las limitaciones inherentes a los métodos convencionales, que involucran la administración de cuestionarios y que suelen enfrentar problemas como la falta de motivación de los estudiantes, la elección de respuestas al azar o la falta de conocimiento por parte de los estudiantes sobre sus propias preferencias de aprendizaje. En contraste, la detección automática tiene la capacidad de predecir de manera continua y en tiempo real los estilos de aprendizaje de cada estudiante mientras participan en su proceso de enseñanza-aprendizaje. Esto significa que es posible seguir y comprender cómo varía el estilo de aprendizaje de un estudiante a lo largo del tiempo, lo que a su vez permite ofrecerle asistencia personalizada y sugerencias de aprendizaje con el objetivo de mejorar su desempeño en el proceso educativo.

Sin embargo, es importante destacar que uno de los desafíos significativos que enfrenta la detección automática es su dependencia del contexto pedagógico. Esto significa que resulta extremadamente complicado adaptar la detección automática a diferentes entornos o incluso a diferentes asignaturas educativas.

La detección automática de estilo de aprendizaje resuelve los inconvenientes asociados con los métodos tradicionales, como los cuestionarios, que pueden presentar desmotivación, respuestas al azar y falta de conocimiento de los estudiantes sobre sus preferencias de aprendizaje. Mediante la detección automática, se pueden predecir los estilos de aprendizaje en tiempo real y de manera transparente durante los procesos de enseñanza y aprendizaje. De esta forma, es posible observar la variación en su estilo de aprendizaje a lo largo del tiempo y ofrecerles ayuda o sugerencias de aprendizaje personalizadas para mejorar su rendimiento. Sin embargo, un inconveniente importante de la detección automática es su dependencia de las prácticas pedagógicas, lo que dificulta su reutilización en otros contextos o en diferentes asignaturas.

REFERENCIAS BIBLIOGRÁFICAS

- Dung, P.Q., & Florea, A.M. (2012). *A Literature-Based Method To Automatically Detect Learning Styles In Learning Management Systems*. Paper presented at the In Proceedings Of The 2nd International Conference On Web Intelligence, Mining And Semantics.
- Essa, S. G., Celik, T., y Human-Hendricks, N. E. (2023). Personalized Adaptive Learning Technologies Based on Machine Learning Techniques to Identify Learning Styles: A Systematic Literature Review. En IEEE Access. 11. pp. 48392-48409.
<https://doi.org/10.1109/ACCESS.2023.3276439>.
- Felder, R. M., y Silverman, L. K. (1988). *Learning styles and teaching styles in engineering education*. Engineering Education, 78(7), 674– 681.
- Felder, R.M. and Spurlin, J. (2005) *Applications, reliability and validity of the index of learning styles*. International Journal of Engineering Education, 21 (1) (2005), pp. 103-112
- Feldman, J., Monteserin, A. y Amandi, A. (2015). *Automatic detection of learning styles: state of the art*. Artif Intell Rev 44, 157–186. <https://doi.org/10.1007/s10462-014-9422-6>

- Guzmán-Camacho, J., y Mendoza González, B. (2023). Perfil de estudiantes de preparatoria en función de su estilo de aprendizaje y descripción a partir del estilo de enseñanza de sus profesores. *Revista RedCA*. 5. 10. <http://dx.doi.org/10.36677/redca.v5i15.20742>.
- Mayer, R. E. (2017). *Using multimedia for e-learning*. *Journal of Computer Assisted Learning*, 33(5), 403–423. <https://doi.org/10.1111/jcal.12197>
- Özpolat E., y Akar, G.B. (2009). *Automatic detection of learning styles for an e-learning system*. *Computers and Education* 53(2), 355–367. <https://doi.org/10.1016/j.compedu.2009.02.018>
- Tocci, A. (2015). Caracterización de perfiles de estilos de aprendizaje en alumnos de Ingeniería según el modelo de Felder y Silverman. *Revista de Estilos de Aprendizaje*. 8. <http://dx.doi.org/10.55777/rea.v8i16.1019>.
- Unesco. (2013). *Enfoques estratégicos sobre las TIC en educación en América Latina y el Caribe*. <https://unesdoc.unesco.org/ark:/48223/pf0000223251>
- Ventura, A. C. (2016). ¿Enseño como aprendí?: el rol del estilo de aprendizaje en la enseñanza del profesorado universitario. *Aula Abierta*, Vol. 44. <https://doi.org/10.1016/j.aula.2016.05.001>.
- Wibirama S., Sidhawara A. P., Lukhayu Pritalia G. and Adji T. B. (2020), *A Survey of Learning Style Detection Method using Eye-Tracking and Machine Learning in Multimedia Learning*. 2020 International Symposium on Community-centric Systems (CcS), 1-6, <https://doi.org/10.1109/CcS49175.2020.9231447>
- Wooldridge, B. (1995). *Increasing the effectiveness of university/college instruction: Integrating the results of learning style research into course design and delivery*. En R. R. Sims y S. Sims (Eds.), *The importance of learning styles: Understanding the implications for learning course design and education* (pp. 49-67) Editorial Greenwood Press.