

**IDENTIFICACIÓN DE ESTILOS DE APRENDIZAJE EN PLATAFORMAS
TECNOLÓGICA (LMS) MEDIANTE ÁRBOLES DE DECISIÓN**

**IDENTIFICATION OF LEARNING STYLES IN TECHNOLOGICAL PLATFORMS
(LMS) THROUGH DECISION TREES**

Guillermo Mario Arturo Salazar Lugo
Instituto Tecnológico de Sonora, México
guillermo.salazar@itson.edu.mx

Armando Lozano Rodríguez
Instituto Tecnológico de Sonora, México
armando.lozano@itson.edu.mx

Jesús Tánori Quintana
Instituto Tecnológico de Sonora, México
jesus.tanori@itson.edu.mx

Ramona Imelda García López
Instituto Tecnológico de Sonora, México
igarcia@itson.edu.mx

Resumen

En el presente estudio se identifican patrones de comportamiento de los estudiantes que permiten clasificarlos de manera automática mientras interactúan con recursos educativos en una plataforma tecnológica de aprendizaje (Learning Management System, LMS, por sus siglas en inglés); dicha clasificación es con base en los estilos de aprendizaje del modelo Felder-Silverman, a partir de la técnica de minería de datos de árboles de decisión. En el estudio participaron 130 alumnos de la carrera de Ingeniería en Software de una universidad del sur de Sonora y se utilizó la metodología descubrimiento del conocimiento en bases de datos (KDD). Se encontró que los estilos visual, sensorial y equilibrado pueden predecirse correctamente en el 75% de los casos. La evidencia sugiere que los estilos propuestos en la teoría seleccionada no se cumplen al cien por ciento de acuerdo con su conceptualización inicial. Lo anterior puede deberse a que la teoría de estilos de aprendizaje no fue diseñada para identificar estilos en estudiantes a distancia con las dimensiones propuestas por sus autores. En un desglose de los materiales disponibles para los estudiantes, se pudo evidenciar que todos los estilos de aprendizaje muestran una preferencia a los de tipo texto, incluso los alumnos visuales; esto considerando que la mayoría de los documentos base del curso son PDF (Portable Document Format – Formato de documento portable) donde el contenido preponderante es texto.

Palabras clave: estilos de aprendizaje, minería de datos educacional, sistemas de gestión del conocimiento.

Abstract

In the present study, patterns and usage characteristics indicate how a student adapts to educational resources in a technological platform (LMS, for its acronym

Learning Management System) based on their learning style, according to the theory of Felder and Silverman (1988), using the data mining of decision trees technique are identified. The study involved 130 Software Engineering students at a university in the south of Sonora, and the knowledge discovery methodology in databases (KDD) was used. It was found that visual, sensitive and balanced styles can be predicted correctly in 75% of cases. The evidence suggests that the styles proposed in the selected theory are not fulfilled one hundred percent according to their initial conceptualization. This may be due to the fact that the theory of learning styles was not designed to identify learning styles in students who are taking courses in distance modality in terms of the dimensions proposed by their authors. In a breakdown of the materials available to the students, it was evident that all learning styles show a preference to those of text type; even the visual students, which could be due to the fact that most of the base documents of the course are PDF (Portable Document Format) material where the predominant content is text.

Keywords: Educational data mining, Knowledge management systems, Learning styles.

1. Introducción

El avance de las tecnologías de la información y la comunicación (TIC) ha propiciado que las personas trasladen muchas de las actividades que anteriormente desempeñaban dentro de los espacios físicos a los entornos virtuales. En este contexto, las actividades comerciales, bancarias, de entretenimiento, sociales e incluso las educativas, han tenido una nueva cabida en la revolución cultural que ha marcado el Internet (Igado, 2007).

Actualmente, la educación ofrece la posibilidad de implementar cursos no solo en las modalidades tradicionales, sino también a través de lo que se conoce

como *e-learning*. Este concepto puede definirse como una modalidad virtual de enseñanza-aprendizaje y consiste en el diseño, puesta en práctica y evaluación de un curso o plan formativo, que se lleva a cabo a través de dispositivos electrónicos que manejan redes computacionales (Area y Adell, 2009).

Una de las características principales del *e-learning* es que el proceso formativo tiene lugar a través de un entorno virtual. En este, se logra la interacción profesor-alumno mediada por una computadora o algún dispositivo electrónico, así como por instrucciones precisas para desarrollar actividades de aprendizaje con recursos educativos puestos a su disposición en forma de videos, tutoriales, simuladores, documentos o materiales multimedia. Lo anterior ha derivado en el desarrollo de plataformas de aprendizaje (LMS por sus siglas en inglés para referir *Learning Management System*), las cuales son sistemas computacionales con fines educativos en los que se desarrollan las actividades formativas y que pueden ser utilizados por estudiantes y maestros de diferentes grados escolares. Feldman, Monteserin y Amandi (2014) clasifican a estas plataformas como Sistemas de Gestión de Aprendizaje, Sistemas Tutor Inteligente y Sistemas Hipermedia Educativos Adaptativos (LMS, ITS y AEHS, respectivamente por sus siglas en inglés).

Estas plataformas de aprendizaje poseen la capacidad de monitorear y almacenar una gran cantidad de datos respecto a los estudiantes y el proceso de enseñanza-aprendizaje. Sin embargo, frecuentemente las decisiones importantes se toman con base en la intuición y experiencia de quien decide, y considerando la información almacenada (Han y Kamber, 2001). En ese sentido, la minería de datos (MD), como herramienta de análisis de información, permite afrontar los desafíos que plantea el hecho de que el ser humano tiene la capacidad de percibir excepciones, anomalías o relaciones rápidamente, pero pierde esa habilidad a medida que la cantidad de datos disponibles se incrementa.

Según Galindo y García (2010), la MD es el área que favorece el hecho de encontrar patrones o información “oculta” mediante técnicas de exploración, agrupación, visualización y análisis en esas grandes cantidades de datos que no pueden ser inspeccionados de forma manual. La minería de datos educacional se ha convertido, en los últimos años, en un punto de interés al utilizar datos de plataformas educativas para comprender mejor el aprendizaje y los entornos en los que este ocurre (LACE, 2016).

Mediante la MD se analiza el proceso de aprendizaje de un estudiante considerando su interacción con el ambiente, debido a que convierte los datos recopilados desde una plataforma educativa en información valiosa que puede poseer gran impacto en la práctica por parte del personal docente o en la investigación educativa (Galindo y García, 2010).

Desde la perspectiva de las diferencias individuales, cada estudiante tiene distintas necesidades y características, tales como su propio estilo de aprendizaje, sus conocimientos previos, su disposición o su propia motivación (Lozano-Rodríguez, 2015). Por lo anterior, cada vez se presta una mayor atención a la influencia que tienen los estilos de aprendizaje y cómo su consideración puede tener un gran impacto en el aprendizaje. Con base en esto, los sistemas educativos toman en cuenta esta característica para mejorar el proceso de enseñanza-aprendizaje (Paredes, 2008).

García-Cué, Santizo-Rincón y Alonso-García (2009) realizaron una investigación documental para reunir un compendio de más de 38 instrumentos para medir estilos de aprendizaje en distintos contextos y para poblaciones diversas. La mayoría de esos instrumentos están enfocados a ambientes presenciales y en realidad son pocos los orientados en entornos a distancia, en donde los estudiantes toman cursos a través de diversas plataformas. Por su parte, Feldman (2014), señala que se utilizan distintos tipos de cuestionarios

diseñados con base en modelos diferentes y para tratar de entender la manera en que los alumnos prefieren aprender o interactuar con su ambiente. Algunos ejemplos de estos son: Myers-Briggs Type Indicator (MBTI) para tipologías de la personalidad asociadas con el aprendizaje, Learning Style Questionnaire (LSQ) y el Index of Learning Styles (ILS) de Felder y Silverman (1988).

2. Planteamiento del problema

Cada vez con mayor frecuencia, diversas universidades en México utilizan Moodle como LMS para algunos cursos en modalidad virtual y virtual-presencial (mixta). Esta plataforma pone a disposición del usuario grandes cantidades de información relacionada con la forma en la que los estudiantes navegan en ella. Esto puede resultar de utilidad para implementar mejoras en el proceso de enseñanza-aprendizaje; sin embargo, en la mayoría de las ocasiones, este hecho se pasa por alto y no se utiliza dicha información para ningún propósito.

Los LMS son usualmente configurados sin tener en cuenta los diferentes estilos de aprendizaje de los usuarios potenciales. En este sentido, a través de un LMS podría implementarse un curso y presentar información que no favorezca a ciertos estudiantes respecto a sus preferencias para aprender, debido a que no es congruente con su estilo de aprendizaje (Paredes, 2008).

Por otra parte, la aplicación de instrumentos para identificar estilos de aprendizaje presenta algunos inconvenientes. Según Feldman et al (2014), llenar un cuestionario es una tarea aburrida que requiere trabajo adicional de los estudiantes dado que algunos de los ellos tienen más de 100 preguntas; por ello, los alumnos tienden a elegir respuestas arbitrariamente si no están conscientes de la importancia o los usos futuros de la información que se obtiene; también pueden verse influenciados por la forma en que estos son formulados, lo que los lleva a dar respuestas percibidas como más apropiadas.

A su vez, los cuestionarios asumen que los estudiantes están conscientes de sus preferencias de aprendizaje, pero esto no siempre es el caso. Finalmente, cabe señalar que los estilos de aprendizaje pueden variar a lo largo del tiempo, según el proceso formativo y madurez del estudiante. Dada la situación anterior y por interés en la temática, se plantea la siguiente interrogante: ¿Cómo identificar los patrones de uso y navegación de los usuarios de un LMS que permitan configurar su estilo de aprendizaje de acuerdo con una cierta teoría?

2.1. Objetivo

Identificar patrones de comportamiento en el uso de un LMS, que permitan clasificar estudiantes de manera automática con base en los estilos de aprendizaje según el modelo Felder-Silverman mientras estos interactúa con recursos educativos en dicha plataforma.

2.2. Justificación

Caracterizar los comportamientos de los estudiantes y su relación con los estilos de aprendizaje de los mismos, permitirá implementar mecanismos para la identificación automática de dichos estilos y la adaptación de los contenidos educativos para favorecerlos o desarrollarlos. Lo anterior representa los primeros pasos hacia la implementación del aprendizaje adaptativo mediado por LMS; es decir, el ajuste del diseño instruccional de los cursos con base al estilo del estudiante, con el fin de optimizar el proceso de aprendizaje; esto a partir de detectar las secciones más visitadas de la plataforma, así como aquellas en las que los estudiantes pasan más tiempo y a las que prestan mayor interés y preferencia de navegación

La identificación de características y patrones de comportamiento de los estudiantes al utilizar una plataforma tecnológica permitirá al personal docente

obtener retroalimentación, evaluar la estructura de los contenidos de un curso y la efectividad que tengan en el proceso de aprendizaje.

2.3. Limitaciones

Por la magnitud del proyecto, se determinó que su alcance era identificar las características y patrones de los estudiantes con base en el rastro de su comportamiento interpretado a partir de la información recopilada en un LMS, relacionado con su estilo de aprendizaje previamente identificado a través de un instrumento de auto reporte.

La información fue recopilada en un LMS llamado Moodle en el Instituto Tecnológico de Sonora, en seis cursos de Programación II con un total de 130 estudiantes inscritos en la materia durante un periodo de 6 meses de enero a junio del 2016.

Se aplicaron técnicas de MD como segmentación de datos, árboles de decisiones con método CHAID, J-48 y técnicas de visualización. El software utilizado para el análisis de los conjuntos de datos fueron los que se tienen disponibles en la institución: RapidMiner Studio y el software estadístico IBM SPSS versión 23 para intentar generar modelos de predicción con la precisión más alta posible.

3. Método

3.1. Tipo de estudio

La investigación se desarrolló bajo el enfoque cuantitativo, de tipo transeccional.

3.2. Participantes

En el presente estudio participaron seis grupos en modalidad mixta (virtuales-presenciales) de la materia de “Programación II” del programa educativo de Ingeniería en Software en el Instituto Tecnológico de Sonora.

En los grupos se encontraban inscritos 130 estudiantes en promedio cada uno contaba con 20 alumnos, quienes cursaban el segundo semestre; 19 son de sexo femenino y 111 de sexo masculino con edades de entre 18 y 20 años.

3,3, Instrumentos

Para la recolección de datos se aplicó el instrumento para calcular el índice de estilos de aprendizaje (ILS) de un estudiante, propuesto por Felder y Silverman (1988). Consta de una serie de 44 preguntas con dos opciones de respuesta cada una (a o b). Cada dimensión en los estilos de aprendizaje está asociada a 11 preguntas de elección correspondiente a una de las categorías de la dimensión (por ejemplo, visual o verbal).

Se utilizó un servidor con la plataforma educativa Moodle para el desarrollo de las clases y la recolección de datos de los alumnos en una base de datos MySQL con el gestor MySQL Workbench (Oracle Corporation, 2016); se analizaron los datos con la herramienta estadística IBM SPSS Statistics, IBM SPSS Modeler y RapidMiner.

3,4, Procedimiento

Se aplicó la metodología llamada descubrimiento del conocimiento en bases de datos (KDD, por sus siglas en inglés) adaptada a los ambientes educativos; esta se muestra en la Figura 1. Dicha metodología consiste en convertir datos de bajo nivel en conocimiento de alto nivel (Pérez Marqués, 2014).



Figura 1. Diagrama de fases del método (Pérez Marqués, 2014)

3.5. Selección y extracción de la información.

En esta etapa se determinan las fuentes de información que pueden ser útiles y dónde conseguirlas; se deben recopilar e integrar los datos, identificar y seleccionar las variables relevantes en los datos para aplicarse técnicas de muestreo en caso de ser necesario y crear un conjunto de datos manejables en la siguiente etapa.

3.6. Pre-procesamiento de la información.

Esta fase es necesaria para mejorar la calidad de los datos para el proceso de minería. Se realizan transformaciones sintácticas de los datos sin modificar su significado; esto con la idea de permitir o facilitar el empleo de alguna técnica de minería en particular. Por ejemplo, la reordenación de los campos y/o registros de la tabla o el ajuste de los valores de los campos a las limitaciones de las

herramientas de modelado (eliminar comas, tabuladores, caracteres especiales, máximos y mínimos para las cadenas de caracteres, etc.).

Como parte de esta fase, se encuentran tareas como la transformación de variables, la obtención de particiones del conjunto de datos y la limpieza de los mismos, que implica realizar operaciones básicas como la normalización, el manejo de valores ausentes y la reducción de redundancia. Existen tareas más específicas como la selección de atributos y el rebalanceo de datos, el cual suele presentarse en este tipo de conjunto de datos.

3.7. Minería de datos.

Con el conjunto de datos pre-procesados, las técnicas de MD pueden ser aplicadas. Para el modelo predictivo de estilos de aprendizaje se propone un árbol de decisiones con el conjunto de datos segmentado por dimensiones de los estilos y la aplicación de rebalanceo de datos para intentar obtener una precisión más alta en los resultados.

Interpretación

Como última fase, los modelos resultantes en la fase anterior son analizados, las salidas de los algoritmos utilizados son revisadas y se identifican cuáles son las variables de comportamiento que están más relacionadas a los resultados esperados. La interpretación de los resultados debe ser lo más clara y sencilla posible, haciendo uso de técnicas de visualización debido a que estas son una ayuda que incrementa el entendimiento para la perspectiva humana.

Posteriormente, se transforma el conocimiento obtenido en acciones dentro del proceso institucional, ya sea recomendando acciones basadas en la observación del modelo y sus resultados, aplicando el modelo a diferentes conjuntos de datos o como parte del proceso. A partir de estos análisis se puede

realizar una interpretación del problema y su magnitud, para la futura toma de decisiones.

4. Resultados

Selección y extracción de la información

Se configuraron cursos virtuales en la plataforma Moodle para la recolección de datos de los estudiantes de Programación II, relacionados con su comportamiento al usar la plataforma y acceder a los contenidos de aprendizaje.

Para la estructura del curso se utilizó el calendario de clases propuesto por la academia. Se crearon seis secciones en el tablero principal de actividades del usuario: en la sección de bienvenida se encuentran los materiales de ayuda y consulta para los estudiantes; en las secciones restantes se encuentran las unidades de competencia en las cuales hay diferentes tipos de contenido (verTabla 1).

Tabla 1. *Materiales disponibles en Moodle*

Materiales	Descripción
Programa de curso	Documento proporcionado por el cuerpo académico donde se describen los temas del curso.
Calendario de clases	Documento donde se especifican las fechas y tiempos del curso.
Tutorial	Material de ayuda para los estudiantes que pueden consultar para diferentes temas.
Tema	Material de texto relacionado a un tema de la clase.
Sesión	Descripción de las asignaciones y ejercicios vistos en una clase presencial.
Chat	Herramienta proporcionada por la plataforma que le permite a los estudiantes comunicarse.
Foro	Herramienta que le permite al docente y sus estudiantes discutir/debatir sobre un tema de la clase.
Gráfico	Material de aprendizaje en formato gráfico como esquemas,

Texto	mapas conceptuales, imágenes, mapas, entre otros. Material de aprendizaje donde el contenido es principalmente texto.
Video	Videos de consulta de temas relacionados al curso.
Ejercicio	Material de clase que funciona como asignación en clase presencial.
Asignación	Material de clase que el docente asigna a sus estudiantes como tarea.
Ejemplo	Material de apoyo para que los estudiantes puedan consultar en- caso de que necesiten ayuda en algún tema.

Con base en la literatura de estilos de aprendizaje y los datos que Moodle registra, relacionados al comportamiento de los usuarios, se seleccionaron indicadores que podrían contribuir en la identificación de sus estilos a partir de un comportamiento específico (ver Tabla 2).

Tabla 2. *Variables de comportamiento seleccionadas*

Indicador	Descripción
Ejemplos vistos	Número de ocasiones en las que el usuario consultó un ejemplo.
Ejercicios visitados	Número de ocasiones en las que el usuario consultó o envió un ejercicio.
Ejercicios enviados	
Materiales vistos	Número de ocasiones en las que el usuario consultó un material de cualquier tipo.
Materiales texto	Número de ocasiones en las que el usuario consultó un material de texto.
Materiales gráficos	Número de ocasiones en las que el usuario consultó un material gráfico.
Outlines vistos	Número de ocasiones en las que el usuario consultó las generalidades del curso.
Número logins	Número de ocasiones en las que el usuario accedió a la plataforma.

Logins mañana	Número de ocasiones en las que el usuario accedió a la plataforma por las mañanas, tardes y noches respectivamente.
Logins tarde	
Logins noche	
Chat participación	Número de ocasiones en las que el usuario participó en un chat en la plataforma.
Chat visto	Número de ocasiones en las que el usuario consultó un chat en la plataforma.
Visitas foro	Número de ocasiones en las que el usuario realizó una visita a cualquier foro.
Participación foro	Número de ocasiones en las que el usuario participó en cualquier foro.

Se realizó una exploración de la base de datos de la plataforma Moodle para ubicar dónde se almacena la información requerida para el desarrollo de la investigación. Se ubicaron las tablas de mayor interés dentro de la base de datos como “*mdl_logstore_standard_log*”, donde se encuentran almacenados los registros de cualquier actividad dentro de la plataforma por parte de todos los usuarios; “*mdl_users*”, con información personal de los usuarios de la plataforma; “*mdl_assign*” y “*mdl_pages*”, donde se almacena la información referente a las asignaciones y páginas creadas por el administrador/profesor de la plataforma.

Posteriormente, se creó una tabla en la base de datos de Moodle llamada “*usr_estilos*” donde se almacenarían los datos de los perfiles ILS de cada alumno, la cual se compuso de un ID (número de identificación) de registro, el ID del estudiante, las respuestas de cada pregunta del instrumento ILS, cuatro variables que representan los resultados, cuatro variables de etiquetado, el estilo de aprendizaje del alumno y el número de iteración (verTabla 3).

Tabla 3. Descripción de los datos almacenados en la tabla *usr_estilos*

Nombre	Descripción
IDRegistro	Identificador único de cada registro que se agrega a la tabla.

IDEstudiente	Identificador del alumno basado en la matrícula escolar.
P1, P2, P3...P44	Respuestas otorgadas por cada alumno en el instrumento ILS.
ACT_REF	Resultado del alumno para la dimensión "Activo-Reflexivo" en la escala de -11 a 11.
SEN_INT	Resultado del alumno para la dimensión "Sensorial-Intuitivo" en la escala de -11 a 11.
VIS_VRB	Resultado del alumno para la dimensión "Visual-Verbal" en la escala de -11 a 11.
SEQ_GLO	Resultado del alumno para la dimensión "Secuencial-Global" en la escala de -11 a 11.
Preferencia1	Etiqueta de la preferencia del alumno en la dimensión "Activo-Reflexivo". Para cada dimensión puede resultar "Equilibrado", "Moderado" y "Fuerte".
Preferencia2	Etiqueta de la preferencia del alumno en la dimensión "Sensorial-Intuitivo". Para cada dimensión puede resultar "Equilibrado", "Moderado" y "Fuerte".
Preferencia3	Etiqueta de la preferencia del alumno en la dimensión "Visual-Verbal". Para cada dimensión puede resultar "Equilibrado", "Moderado" y "Fuerte".
Preferencia4	Etiqueta de la preferencia del alumno en la dimensión "Secuencial-Global". Para cada dimensión puede resultar "Equilibrado", "Moderado" y "Fuerte".
Estilo	Estilo de aprendizaje que tiene más ponderación en los resultados.
Iteración	Número de iteración en la que se obtuvo el estilo, es decir, en cuál de las ocasiones en que se hizo la aplicación del instrumento se obtuvo el registro actual.

Al tener creada la estructura de la tabla donde se almacenaría la información recopilada se aplicó una primera iteración del instrumento ILS a 130 estudiantes pertenecientes a los cursos de Programación II utilizando la herramienta web proporcionada por la North Carolina State University (Soloman & Felder, s.f.).

Una vez obtenidos los resultados del instrumento, estos se capturaron Microsoft Excel, para posteriormente integrarlos en la tabla "usr_estilos" en la base

de datos de Moodle. Con la información reunida se dispone de un conjunto de datos formado por 30 variables asociadas a cada uno de los estudiantes inscritos en los cursos.

Pre-procesamiento de la información

Se procedió a identificar a aquellos estudiantes cuyo estilo de aprendizaje no era claro al tener igualadas dos o más dimensiones en sus resultados del instrumento ILS; a todos los alumnos con esta característica se le agregó como estilo de aprendizaje la etiqueta “Equilibrado” (ver Figura 2).

Fuerte Reflexiv	Fuerte Intuitivo	Moderada Verl	Equilibrada	Intuitivo
Moderada Acti	Moderada Sen	Equilibrada	Moderada Secuencial	
Moderada Acti	Equilibrada	Moderada Visu	Equilibrada	
Moderada Refl	Equilibrada	Moderada Visu	Equilibrada	
Fuerte Reflexiv	Equilibrada	Moderada Visu	Equilibrada	Reflexivo

↓

ResDimens	ResDimens	ResDimens	ResDimension4	Estilo
Equilibrada	Equilibrada	Equilibrada	Equilibrada	Equilibrado
Equilibrada	Equilibrada	Moderada Verl	Moderada Secuencial	Verbal

Figura 2. Conjunto de datos limpio

Posterior a esto, se crearon dos variables para etiquetar estudiantes que cumplieran con dos características: que ingresara al menos 10 veces y que contara con el instrumento ILS respondido (ver Figura 3).

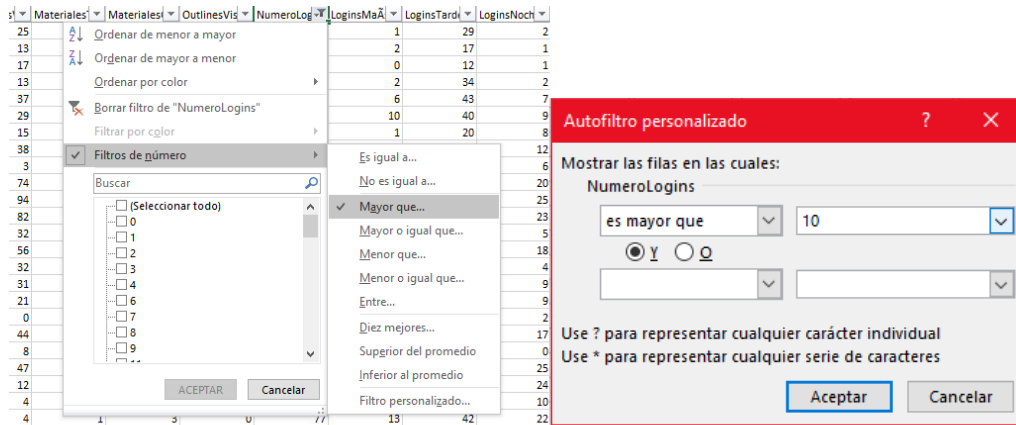


Figura 3. Aplicación del filtro al conjunto de datos

Dentro de los seis grupos utilizados se encontraron 67 casos ($n = 13$ mujeres, 54 hombres) con los cuales se hicieron todos los análisis posteriores; el 80.60% de la población fue identificada con sexo masculino y el 19.40% restante, femenino (ver Figura 4).




Figura 4. Población de análisis

Posteriormente, se identificó la prevalencia de estilos de aprendizaje donde se encontró que el visual, equilibrado y sensorial son los más altos, con 20,12 y 10 estudiantes respectivamente. Por otra parte, los estilos con menos alumnos son el global, intuitivo y verbal con 2, 3 y 3 (ver Tabla 4 y Figura 5).

Tabla 4. *Prevalencia de estilos de aprendizaje en estudiantes*

Estilo	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Activo	9	13.4	13.4	13.4
Equilibrado	12	17.9	17.9	31.3
Global	2	3.0	3.0	34.3
Intuitivo	3	4.5	4.5	38.8
Reflexivo	5	7.5	7.5	46.3
Secuencial	3	4.5	4.5	50.7
Sensorial	10	14.9	14.9	65.7
Verbal	3	4.5	4.5	70.1
Visual	20	29.9	29.9	100.0
Total	67	100.0	100.0	

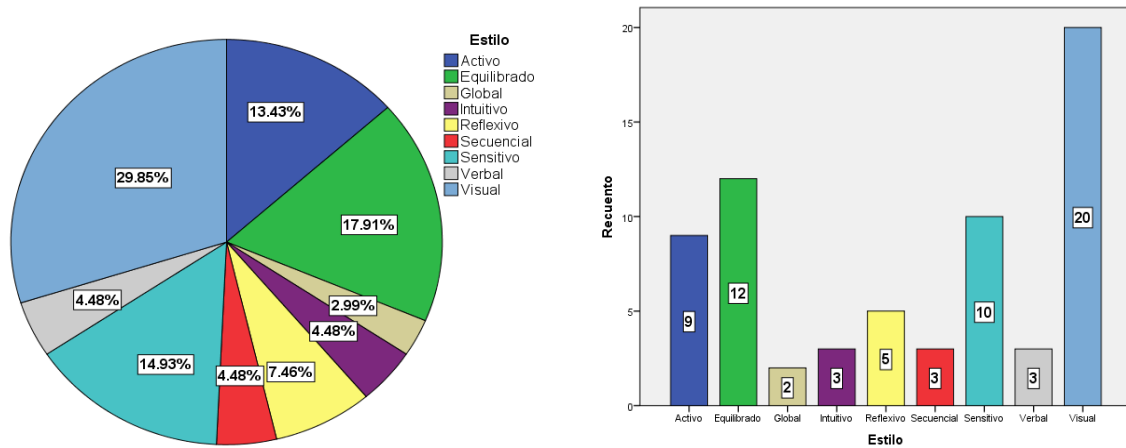


Figura 5. Porcentajes de estilos de aprendizaje

A partir de lo anterior se analizaron todas las variables para saber qué tanto se relacionan con las dimensiones de estilos de aprendizaje. Se identificaron las siguientes variables con una relación significativa al .05: “EjemplosVistos”, “EjerciciosVisitados”, “EjerciciosEnviados”, “MaterialesVistos”, “OutlinesVistos”, “NumeroLogins” (ver Figura 6).

		EjemplosVistos	EjerciciosVistos	MaterialesVistos	EjerciciosEnviados	OutlinesVistos	NumeroLogins	Logins Mañana	Logins Tarde	Logins Noche
Dimensión Activo/Reflexivo	Correlación de Pearson	.056	.067	.079	.056	.249	.232	.137	.264	.003
	Sig. (bilateral)	.646	.581	.518	.643	.038	.053	.257	.027	.978
	N	70	70	70	70	70	70	70	70	70
Dimensión Sensitivo/Intuitivo	Correlación de Pearson	.035	-.062	.058	-.046	.231	-.005	.012	-.017	.024
	Sig. (bilateral)	.771	.609	.631	.708	.054	.964	.920	.887	.842
	N	70	70	70	70	70	70	70	70	70
Dimensión Visual/Verbal	Correlación de Pearson	.065	.137	.020	.164	.003	.146	.141	.105	.171
	Sig. (bilateral)	.590	.257	.869	.175	.978	.229	.245	.387	.156
	N	70	70	70	70	70	70	70	70	70
Dimensión Secuencial/Global	Correlación de Pearson	-.239	-.176	-.257	-.056	-.099	-.128	-.051	-.155	.005
	Sig. (bilateral)	.047	.144	.032	.648	.415	.292	.674	.201	.969
	N	70	70	70	70	70	70	70	70	70

** La correlación es significativa en el nivel 0,01 (bilateral).

* La correlación es significativa en el nivel 0,05 (bilateral).

c. No se puede calcular porque, como mínimo, una de las variables es constante.

Figura 6. Correlaciones entre variables del análisis y las dimensiones de estilos de aprendizaje

En un desglose de los materiales disponibles a los estudiantes, se comprobó que todos los estilos de aprendizaje muestran una preferencia a los de tipo texto; incluso los alumnos visuales, quizá debido a que la mayoría de los documentos base del curso son PDF donde el contenido preponderante es texto (ver Figura 7). Lo anterior puede considerarse obvio si se toma en cuenta que los estudiantes trabajaron en la modalidad virtual, donde este tipo de materiales son usados comúnmente; sin embargo, la plataforma contaba también con la opción de video y los estudiantes identificados como visuales, optaban también por los documentos en PDF.




Figura 7. Desglose de los materiales vistos por estilo de aprendizaje

Relacionado con la hora de ingresar en la plataforma, los estudiantes de estilo global fueron los únicos que prefirieron hacerlo por las mañanas, mientras que los demás mostraron comportamientos similares al entrar por las tardes en la mayoría de las veces (ver Figura 8). Al respecto, valdría la pena relacionar las dimensiones que proponen Dunn y Dunn (1978) sobre las preferencias cronobiológicas en donde se clasifican estilos de personas que son diurnas,

vespertinas o nocturnas. La evidencia tal y como se presenta en los datos obtenidos, parece sugerir que existe una relación entre el estilo global de la teoría de Felder con la preferencia matutina de la teoría de los Dunn.




Figura 8. Desglose de Logins por estilo de aprendizaje

Los estilos equilibrado, reflexivo y sensorial tuvieron un mayor número de visitas a los ejercicios, así como a su entrega (ver Figura 9). Las características mencionadas en la clasificación que hace Felder y Silverman (1988) sobre los

estudiantes que presentan el estilo sensorial refieren precisamente la necesidad de practicar lo que desean aprender; a diferencia de los intuitivos que se aburren con la ejercitación continua. Los estudiantes que presentan el estilo reflexivo parecen no tener una relación directa con las características que se mencionan en la teoría con su predilección por los ejercicios.




Figura 9. Relación entre la cantidad de ejercicios visitados y enviados

Minería de datos

Se llevaron a cabo varios experimentos para hacer comparaciones entre los diferentes algoritmos de la técnica de árboles de decisión. Primero, se utilizaron todos los estilos de aprendizaje; la variable dependiente elegida fue “estilo”, pues a partir de ella se pretendía clasificar a los estudiantes. Como independientes se tomaron las variables más relevantes, las cuales se identificaron previamente (ver Figura 10).

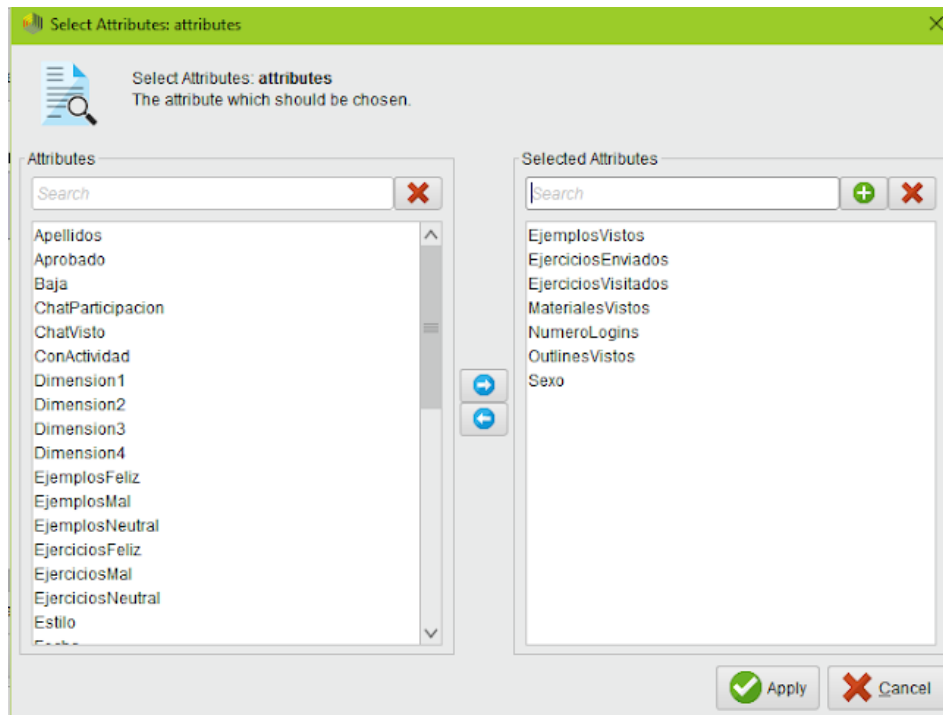


Figura 10. Variables de análisis

Una vez ejecutado el proceso se obtuvieron resultados con niveles de precisión por debajo del 30% y resultó ser poco claro el comportamiento que un estudiante debe tener para pertenecer a un grupo en particular; por otra parte, se encontró que aquellos estilos con mayor cantidad de sujetos son los que tienen

porcentajes más elevados de precisión y se destacan los estilos “Visual”, “Sensorial” y “Equilibrado”.

En una siguiente fase, se segmentó la población creando nuevos conjuntos de datos por dimensiones de estilos de aprendizaje mediante el operador “Filter examples” del software RapidMiner (ver Figuras 11 y 12). Los resultados obtenidos muestran que la variable más importante para definir los estilos son los ejercicios visitados y los porcentajes mejoraron comparándolos con el experimento anterior en la dimensión “Sensorial – Intuitivo” y “Visual – Verbal” con un 70% y 86.67% respectivamente.




Figura 11. Filtrado de estilos de aprendizaje

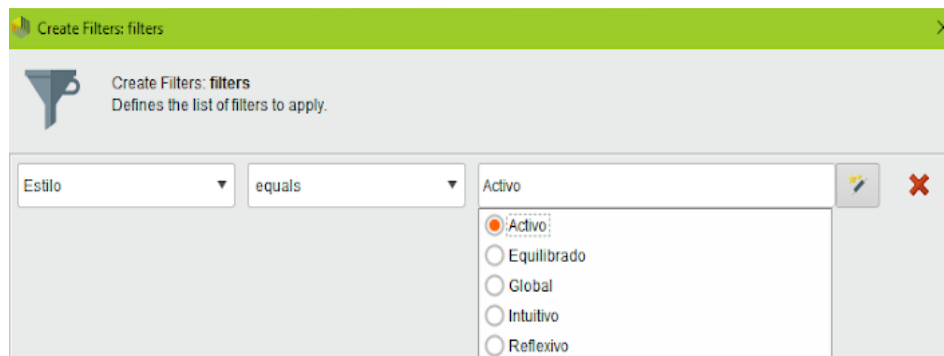


Figura 12. Detalle del filtrado

Con el fin de aumentar la precisión de los modelos diseñados anteriormente, se decidió utilizar el algoritmo J-48 de Weka (Waikato Environment

for Knowledge Analysis) (Hall, Frank, Holmes, Pfahringer, Reutermann & Witten, 2009). El único resultado favorable fue el que se obtuvo en la dimensión “Activo – Reflexivo”; en donde la precisión del modelo subió un 10%; en las otras dimensiones no se presentaron cambios.

Se aplicó un rebalanceo de datos en cada dimensión, tomando como referencia al grupo con menor cantidad de estudiantes para igualar a la población del grupo contrario. Como resultados, no hubo un modelo en específico que mejorara sus predicciones; todos ellos bajaron de porcentaje e incluso el modelo de la dimensión “Secuencial – Global” resultó con un grado de precisión completamente nulo.

Por último, se identificó que los estilos de aprendizaje con una población similar son “Visual”, “Equilibrado” y “Sensorial” y se decidió realizar otro análisis; se encontró que este modelo predice con un 76.5% de confiabilidad los tres estilos mencionados anteriormente basándose en la cantidad de outlines, el número de logins y los ejercicios visitados como variables más significativas a la hora de relacionar a los estudiantes (ver Figuras 13 y 14).

accuracy: 76.50% +/- 14.50% (mikro: 76.19%)

	true Visual	true Equilibrado	true Sensitivo	class precision
pred. Visual	16	3	3	72.73%
pred. Equilibrado	2	9	0	81.82%
pred. Sensitivo	2	0	7	77.78%
class recall	80.00%	75.00%	70.00%	

Figura 13. Tabla de resultados con los estilos de aprendizaje más poblados

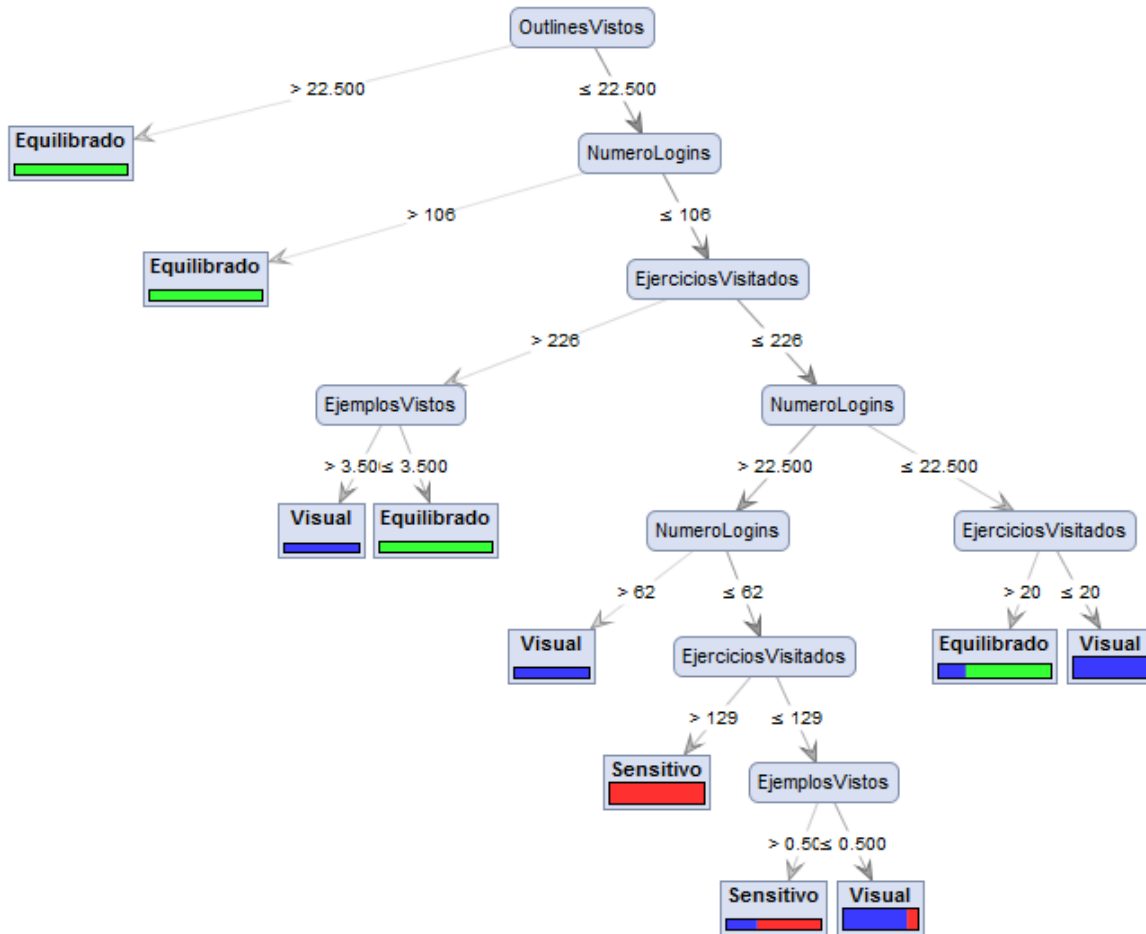


Figura 14. Árbol de decisión con los estilos de aprendizaje más poblados

5. Conclusiones

El objetivo de este trabajo fue identificar de manera automática, patrones de comportamiento de los estudiantes al momento de interactuar con recursos educativos en un LMS, con el fin de hacer una clasificación de ellos con base en sus estilos de aprendizaje de acuerdo al modelo Felder-Silverman. Con los análisis realizados se evidencia que la identificación de patrones de uso de la plataforma permite generar estrategias para mejorar su utilización.

En los resultados, se encontró que, a pesar de que se obtuvo un modelo con un alto porcentaje de precisión en sus predicciones, este solo puede distinguir con mayor prevalencia tres estilos de aprendizaje. Esto es, no es posible predecir el comportamiento de los ocho estilos identificados en la teoría de Felder y Silverman (1988). Lo anterior permite sugerir que es necesario seleccionar una teoría diferente con un menor número de estilos identificados; por ejemplo el CHAEA (Alonso, Gallego & Honey, 2012; León, Schilardi, Segura & Polenta) que cuenta con cuatro estilos perfectamente identificados o una teoría de estilos más ad hoc a la modalidad a distancia como el QuironTest (Lozano-Rodríguez, Tijerina-Salas y García-Cué, 2016); a pesar de que este contiene también ocho estilos, está más acorde a los requerimientos y características de la educación a distancia. Esto ayudaría a determinar si el sistema de minería de datos pudiera precisar la predicción con base en la identificación de los estilos diagnosticados a través de un instrumento de auto reporte.

La reestructuración de los materiales de aprendizaje en la plataforma es un punto a resolver en el futuro, tomando en cuenta que incluir más variedad de contenido podría ayudar a generar más información por parte de los estudiantes y así tener un conjunto de datos con el cual poder aplicar otras técnicas de minería.

Otro aspecto que debe tomarse en cuenta es promover el uso de la plataforma por parte de los estudiantes, debido a que en ocasiones esta es usada como un recurso “opcional” por parte de algunos maestros; esto dificulta que los alumnos proporcionen una retroalimentación real de su comportamiento, lo que conlleva a contar con un conjunto de datos carente de información suficiente que dificultan su análisis.

La alternativa de identificación automática de los estilos de aprendizaje, a través de los hábitos de navegación que presentan los estudiantes en una plataforma LMS, abre una veta importante de investigación dado que permitiría

optimizar los procesos de entrega de cursos virtuales más ajustados a las necesidades de los usuarios. Por ejemplo, el sistema que manejan plataformas comerciales como Amazon o Facebook, que identifican los patrones de navegación para presentarle al usuario artículos o información relacionada a lo que anda buscando.

6. Referencias

- Alonso, C.M., Gallego, D.J. y Honey, P. (2012) (8ª. Ed.). *Los estilos de aprendizaje: Procedimientos de diagnóstico y mejora*. Bilbao, España: Mensajero.
- Area, M., y Adell, J. (2009). eLearning: Enseñar y aprender en espacios virtuales. En J. De Pablos (Coord). 391-424. *Tecnología Educativa. La formación del profesorado en la era de Internet*. Málaga: Aljibe.
- Dunn, R. y Dunn, K. (1978). *Teaching students through their individual learning styles*. Reston, VA: Reston Publishing.
- Felder, R. M. y Silverman, L.K. (1988). Learning and teaching styles in the engineering education. *Engineering Education*, 78 (7), 674-681.
- Feldman, J., Monteserin, A. y Amandi, A. (2014). Automatic detection of learning styles: state of the art. *Artificial Intelligence Review*. 44 (157) 1573-7462. doi: <https://doi.org/10.1007/s10462-014-9422-6>
- Galindo, Á. J., y García, H. Á. (2010). *Minería de datos en la educación*. Madrid, España: Universidad Carlos III de Madrid.
- García-Cué, J.L., Santizo-Rincón, J.A. y Alonso-García, C.A. (2009). Instrumentos de medición de estilos de aprendizaje. *Revista de Estilos de Aprendizaje*, 2 (4), 1-19.

- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., y Witten, I. H. (2009). *The WEKA Data Mining Software: An Update*. SIGKDD Explorations. Recuperado de WEKA: Data Mining Software in Java: <http://www.cs.waikato.ac.nz/ml/weka/>
- Han, J., y Kamber, M. (2001). *Data Mining: Concepts and Techniques*. USA: Academic Press.
- Igado, M. F. (2007). *La Telemática en los Procesos Educativos*. Huelva, España: Universidad de Huelva.
- LACE, P. (26 de Junio de 2016). *LACE*. Recuperado de What are learning analytics?: <http://www.laceproject.eu/faqs/learning-analytics/>
- León, O.A., Schilardi, A.R., Segura, S.M. y Polenta, C. (2016). Estilos de aprendizaje y objetos virtuales para enseñanza. *Revista de Estilos de Aprendizaje*, 9(18), 96-116.
- Lozano-Rodríguez, A. (2015). *Estilos de aprendizaje y enseñanza: un panorama de la estilística educativa*. Ciudad de México, México: Trillas.
- Lozano-Rodríguez, A., Tijerina-Salas, A., y García-Cué, J. L. (2016). Implementación del instrumento Quirontest para medir estilos de aprendizaje en estudiantes de pregrado en línea. *Revista de Estilos de Aprendizaje*, 9(17), 240-267.
- Oracle Corporation. (01 de Agosto de 2016). *MySQL Workbench*. Recuperado de MySQL Workbench: <https://www.mysql.com/products/workbench/>
- Paredes-Barragán, P. (2008). *Una propuesta de incorporación de los estilos de aprendizaje a los modelos de usuario en sistemas de enseñanza adaptativos*. Madrid: Universidad Autónoma de Madrid.
- Pérez Marqués, M. (2014). *Minería de datos a través de ejemplos*. Madrid, España: RC Libros.

Soloman, B. A., y Felder, R. M. (s.f.). *Index of Learning Styles Questionnaire*.
Disponibile en: <http://www.engr.ncsu.edu/learningstyles/ilsweb.html>

Received: March, 2018

Approved: April, 2019