



HERRAMIENTA TECNOLÓGICA PARA LA DETECCIÓN DE ESTILOS DE APRENDIZAJE EN LA FACULTAD DE INGENIERÍAS DE LA UNIVERSIDAD FRANCISCO DE PAULA SANTANDER OCAÑA

Claudia Marcela Durán Chinchilla, Alveiro Alonso Rosado Gómez, Malka Irina Cabellos Martínez

**Universidad Francisco de Paula Santander
Ocaña, Colombia**

Resumen

Las nuevas corrientes pedagógicas, en este momento muestran su interés por estudiar a profundidad los procesos de aprendizaje de los estudiantes ya que sería inútil dedicarse a investigar los procesos y las didácticas de la enseñanza si no se aborda de la misma manera la forma de aprender de los docentes, por lo que cada vez se hace más importante tomar en cuenta las variables individuales que inciden en la capacidad de aprendizaje.

Desde la perspectiva anterior, surge la idea de realizar una investigación que dé lugar al diseño de una herramienta tecnológica que permita detectar los estilos de aprendizaje de los estudiantes de ingenierías de la universidad Francisco de Paula Santander Ocaña, se parte de la primera fase del estudio en el cual se determinaron los estilos de aprendizaje basados en la teoría de Felder – Silverman y que mediante la aplicación de minería de datos se podía conocer a los estudiantes con más probabilidad de fracaso en la materia, es así como en este artículo se muestra como se llegó a la automatización en la detección de los estilos de aprendizaje mediante la construcción de un software que permite aplicar aprendizaje supervisado para predecir los estudiantes que tienen probabilidad de perder la materia de Cálculo. El software sigue el proceso de extracción del conocimiento en bases de datos; ejecutando las fases de selección, limpieza, transformación y minería de datos, para producir una salida que muestre el porcentaje de probabilidad que tiene un estudiante de reprobado el curso; esta aplicación permite de manera más rápida y eficiente la detección de los estilos de aprendizaje de los estudiantes para que con los datos arrojados los docentes se planteen estrategias metodológicas que ayude a los

estudiantes a tomar conciencia en cuanto a sus propios procesos de aprendizaje, en función de las exigencias del entorno académico y social, reforzando así el rendimiento académico en términos de notas y por su puesto tener una gama amplia de recursos de enseñanza y aprendizaje.

Palabras clave: estilos de aprendizaje; inteligencia artificial; minería de datos

Abstract

Teaching new trends, at this time show their interest in studying in depth the learning process of students as it would be useless to engage in research and teaching processes of teaching if not addressed in the same way how to learn the Dicent, so every time it becomes more important to take into account individual variables that affect learning ability.

From this perspective, the idea of conducting research that will lead to the design of a technological tool to detect learning styles of engineering students at the Francisco de Paula Santander Ocaña university is part of the first phase of the study in which learning styles based on the theory of Felder were determined - Silverman and by applying data mining could meet the students most likely to fail in the field, so as this article shows how it came to automating the detection of learning styles by building software that allows supervised learning applied to predict students who are likely to lose the art of calculation. The software follows the extraction of knowledge in databases; running phases of selection, cleaning, processing and data mining, to produce an output that shows the percentage of probability that a student failing the course; This application allows faster and more efficient detection of learning styles of students to the data obtained with teachers teaching strategies to help students become aware arise in their own learning processes, based the demands of the academic and social environment, strengthening academic performance in terms of notes and of course have a wide range of teaching and learning resources.

Keywords: learning styles; artificial intelligence; data mining

1. Introducción

Partiendo de los datos de desempeño académico de los estudiantes de la Facultad de Ingenierías de la Universidad Francisco de Paula Santander Ocaña de los programas de Ingeniería Civil, Ingeniería Mecánica e Ingeniería de Sistemas desde el año 2012 y tomando como fuente de información el Sistema de Información Académica (SIA), se evidenciaron los indicadores académicos, en donde, el 60% en promedio de los estudiantes matriculados pierden esta asignatura. En la búsqueda de soluciones para disminuir la cantidad de estudiantes que reprueban el curso, se encontraron teorías como las propuestas por González-Tirados , Kolb , Mainemelis y Boyatzis, quienes afirman que el éxito académico y profesional, no solo depende de tener

conocimientos y desarrollar habilidades, sino que también depende de la disponibilidad de aprender de los individuos y de la capacidad para enfrentar al mundo de hoy, de adaptarse y dominar las diferentes circunstancias que el medio pone a su disposición.

Desde la anterior perspectiva las instituciones de educación deben invertir tiempo en determinar cómo los estudiantes aprenden y cuál es su capacidad para aprender, factor importante para alcanzar el éxito, tanto individual como colectivo, académico, profesional y empresarial.

En este marco, los estilos de aprendizaje deben determinar y explicar cómo cada individuo aprende, cómo construye el conocimiento y no se queda en mera repetición; el conocer estos factores permite a los docentes e instituciones educativas emprender caminos que permitan optimizar resultados de formación y de competencia profesional.

(Honassen & Grabowsky, 1993) Contribuyen a través de una proximidad comprensiva de las variadas diferencias individuales en relación con la instrucción y los distintos instrumentos utilizados para medirlas, estos autores manifiestan que los individuos difieren en su habilidad general, en aptitudes y preferencias para procesar información, construir significados y aplicarlos a nuevas situaciones; los individuos también difieren en sus capacidades para desempeñar tareas y desarrollar productos en el ámbito académico y laboral, así mismo, las distintas tareas y productos de aprendizaje requieren utilizar diferentes habilidades, aptitudes y preferencias, estas capacidades generales y preferencias afectan a la capacidad de los estudiantes para llevar a cabo diferentes productos de aprendizaje.

Desde lo anterior, y en lo que respecta a esta propuesta de investigación, se partió de un estudio previo en el que se determinaron los estilos predominantes de los estudiantes de cálculo de los programas de ingeniería civil, mecánica y sistemas, de la Universidad Francisco de Paula Santander Ocaña, para ello se tuvo en cuenta la teoría de estilos de aprendizaje propuestos por Felder y Silverman; sin embargo, se vio la necesidad de elaborar un software que sigue el proceso de extracción del conocimiento en bases de datos; ejecutando las fases de selección, limpieza, transformación y minería de datos, para producir una salida que muestre el porcentaje de probabilidad que tiene un estudiante de reprobado el curso, a partir de los datos generados se puede determinar de manera eficaz y eficiente los estilos de aprendizaje de los estudiantes para con ello proponer estrategias que apoyen la manera de enseñar del profesor y de aprender de los estudiantes, factor clave en la formación de los profesionales.

2. Reflexiones Conceptuales

Existen variadas definiciones en cuanto a estilos de aprendizaje, sin embargo, se abordarán los conceptos más contemporáneos como el planteado por Hunt, citado por (McCarthy, 2011) en el que dice que los estilos de aprendizaje son: "las condiciones

educativas bajo las que un discente está en la mejor situación para aprender, o que estructura necesita el discente para aprender mejor” (p.5).

Así mismo, Se han concebido varias propuestas para abordar el tema de estilos de aprendizaje, elaborándose diversas clasificaciones para explicar las particularidades que cada individuo tiene y que predisponen su manera de aprender, sin embargo en el caso particular de este estudio se tuvieron en cuenta teorías relevantes, como la de Felder y Sivermar (1988), el cual clasifica los estilos de aprendizaje en cuatro dimensiones (p. 11): activo reflexivo; sensitivo intuitivo; secuencia global, Visual verbal.

Estas dimensiones parten de las preguntas realizadas por (Curry, 1987) en cuanto a los estilos de aprendizaje: ¿Cómo progresa el estudiante en su aprendizaje? ¿Qué tipo de información perciben preferentemente los estudiantes? ¿Con qué tipo de organización de la información está más cómodo el estudiante a la hora de trabajar? ¿Cómo prefiere el estudiante procesar la información? ¿A través de qué modalidad es la información cognitiva más efectivamente percibida? (p. 32).

De allí que (Claxton & Murrell, 1987) sugieren que los estilos de aprendizaje, en los estudiantes de educación superior deben estar clasificados en los siguientes modelos: Modelos de personalidad, Modelos de procesamiento de la información, Modelos de interacción social, Modelos de preferencia de instrucción (p.53).

Dada la cantidad de estudiantes que toman el curso de cálculo diferencial, tratar de hacer un seguimiento individual del desempeño académico de estos se convierte en una tarea complicada; por esta razón se hace necesario utilizar herramientas que agilicen la captura y detección de datos relevantes que puedan ser utilizados como soporte para la toma de decisiones que busquen aumentar el rendimiento académico. Es por esta razón que este proyecto trabaja con Minería de Datos (MD), la cual integra técnicas y herramientas que permiten descubrir el conocimiento oculto que encierran los datos (Han & Kamber, 2006). La MD, enfoca el descubrimiento del conocimiento en dos tipos de aprendizaje; uno de ellos el supervisado, se enfoca en predecir el comportamiento futuro. El otro tipo de aprendizaje es el no supervisado cuya finalidad es la de establecer la afinidad que tienen los datos entre si y de cómo esta puede reflejar una situación que no se tenía identificada (Witten I. H., 2011).

Como en este proyecto se enfoca en determinar el rendimiento del estudiante a partir de su estilo de aprendizaje; es decir determinar cuál estudiante aprobara y cual no lo hará, esta etiqueta se le llama clase y para cada estudiante se le asigna un valor que indica cual fue su desempeño en el curso. Como lo que se busca es predecir cómo será el comportamiento del estudiante a partir de datos históricos, se realizó un estudio de tipo supervisado, como técnica para determinar el modelo se utilizó arboles de decisión (Hernandez Orallo, Ramirez Quintana, & Ferri Ramirez, 2004).

3. Metodología

El proceso que sigue la herramienta de detección de estilos de aprendizaje y predicción de bajo rendimiento, se fundamenta en un estudio realizado por la universidad en donde se aplicó la minería de datos, con el objetivo de conocer que estudiantes pueden ser más propensos a reprobado la materia de cálculo diferencial a partir de su estilo de aprendizaje. A continuación se hace una síntesis de los resultados de la investigación antes mencionada, la cual fue tomada como insumo para el comportamiento de la aplicación construida.

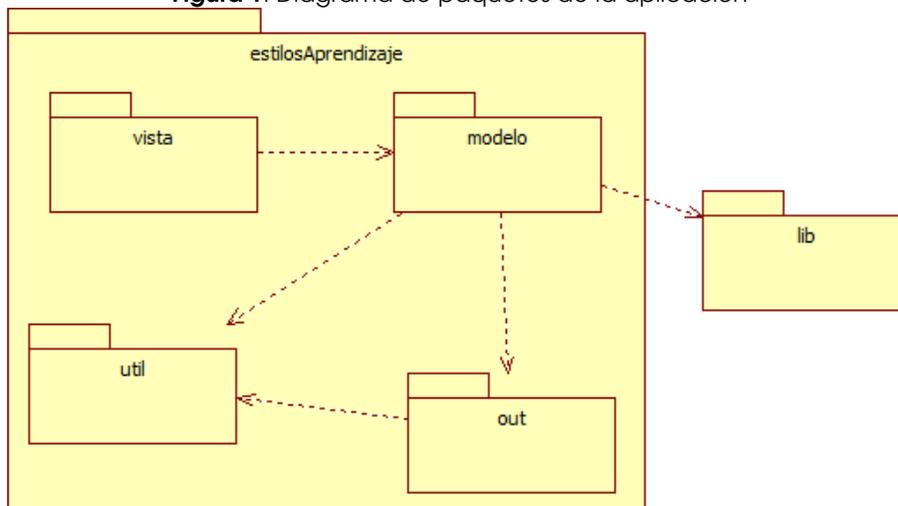
A los estudiantes de la materia cálculo diferencial, desde el año 2013, se les aplica un instrumento semestralmente que contiene las preguntas y opciones de respuesta propuestas por Felder y Silverman (Felder & Brent, 2005). A la información recolectada se les aplica las fases del proceso de extracción del conocimiento en bases de datos (KnowledgeDiscovery in Databases, KDD); para definir un modelo que sea capaz de predecir la probabilidad de fracaso o éxito del estudiante al finalizar la materia (Ferri Ramirez, Hernandez Orallo, & Ramirez, 2004).

El conjunto de datos inicial estaba conformado por un total de 388 estudiantes, caracterizados mediante 17 atributos. Tanto los registros como los atributos fueron reducidos los primeros por tener inconsistencias o estar duplicados (Ferri *et al.*, 2004) y los segundos por no corresponder a un comportamiento común dentro del conjunto de datos (Rodríguez Rodríguez, 2010) o por no ser escogidos por varios algoritmos de selección (Witten, Frank, & Hall, 2011), o por tener una baja frecuencia de aparición en los diferentes algoritmos de renqueo (Guyon & Elisseeff, 2003). Al final de este proceso quedaron 293 registros y solo 4 atributos.

Dado que lo que se pretendía hacer una predicción se aplicó aprendizaje supervisado, utilizando solamente técnicas predictivas (Fayyad, Piatetsky Shapiro, Smyth, & Uthurusamy, 1996); las comprenden los árboles de decisión, regresión logística, redes neuronales y métodos bayesianos (Quinlan, 1989). Para la construcción del modelo se estableció un conjunto de datos de entrenamiento y otro conjunto de datos para la predicción (Baumgartner & Serpen, 2009). La técnica que mejor resultados produjo fue la de árboles de decisión con el algoritmo *DecisionStump* (Witten, Frank, & Hall, 2011), en donde el porcentaje de acierto estuvo 72.7% y el de error en 27.2%, con el mejor valor de kappa con 0.4294. Al modelo generado se aplicó la función *weka.classifiers.trees.J48*, con el ánimo de evaluar la capacidad de predicción (Cerroni, Moro, Pirini, & Ramilli, 2013). Los resultados de predicción muestran que cuando el estudiante reprueba se puede predecir con un nivel de acierto mejor mientras que cuando aprueba el nivel baja.

La figura 1, muestra la estructura de la aplicación creada, se utiliza el diagrama de paquetes, para especificar qué conjunto de elementos son los que conforman la aplicación y como está establecida las dependencias entre ellos (Larman, 2002).

Figura 1. Diagrama de paquetes de la aplicación



Fuente. Autores del proyecto

La síntesis del conjunto de archivos que contiene la aplicación, la resume el diagrama de paquetes. A continuación se describe el contenido de cada uno de ellos:

vista. Este paquete contiene todas las interfaces gráficas, con las cuales interactúa el usuario. Este paquete, consiste en desacoplar la lógica de la aplicación de la vista, buscando que la aplicación pueda ser desplegada en cualquier dispositivo (Larman, 2002).

modelo. Contiene, toda la lógica de la aplicación; es decir toda la programación que fue desarrollada para cumplir con las consultas y procesamiento de la información que se genera entre los archivos y datos que identifican los estilos de aprendizaje y los algoritmos de MD (Marozzo, Talia, & Trunfio, 2013).

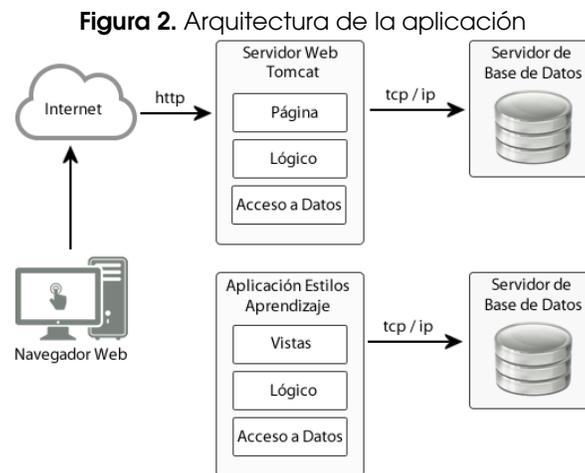
out. Este paquete contiene los archivos que son generados por la aplicación. Estos archivos son creados por los algoritmos de MD y están representados por los archivos que contienen los modelos y los que contienen los conjuntos de datos.

util. Todas las clases que le prestan servicios a otras clases, están contenidas en este paquete, las validaciones y procesos comunes a más de una clase, son centralizadas aquí.

lib. Contiene un conjunto de clases compiladas en lenguaje *Java*, que son utilizadas por las diferentes funcionalidades para realizar las tareas de MD (Lichtenwalter & Chawla, 2011). Las clases son las mismas que utiliza la aplicación WEKA, la cual es un proyecto de la universidad de Waikato y tiene como objetivo proporcionar un conjunto de algoritmos de aprendizaje de máquina, para hacer MD. Esta herramienta permite realizar aprendizaje supervisado y no supervisado. Posee una arquitectura modular la cual ayuda a la actualización y adición de nuevos módulos (Hall, Frank, Holmes, Pfahringer, Reutemann, & Witten, 2009).

4. Resultados

Además de los paquetes en los que se agrupan el conjunto de clases que integran la aplicación, se puede resumir las funcionalidades del software en cinco procesos; inicia con el cargue de los registros y termina con la generación de un nuevo modelo, pasando por la estructuración, selección, limpieza y transformación de los datos (Ferri *et al.*, 2004). La figura 2, muestra la arquitectura de la herramienta, en ella se puede observar las dos aplicaciones que fueron creadas para la sistematización del proceso; por un lado está la plataforma en línea que se encarga de la captura, almacenamiento y tratamiento de las encuestas presentadas por los estudiantes. Por otro lado está la aplicación de estilo de aprendizaje que se encarga del procesamiento y ejecución de técnicas de MD a la información de los estudiantes. Todos los procesos que se adelantan en las dos aplicaciones son almacenados tanto en archivos separados por comas, como en bases de datos.



Fuente. Autores del proyecto

A continuación se hace una especificación informal del funcionamiento de la aplicación (SommerVile, 2005).

Aplicación de la prueba en línea. Al inicio del proceso de inducción se le aplica a los estudiantes un cuestionario, el cual contiene las preguntas y respuestas propuestas por Felder y Silverman, en el, los estudiantes registran sus datos personales y seleccionan las respuestas con las que más se identifican. Una vez se registran las respuestas el sistema asocia a cada estudiante su estilo de aprendizaje.

Cargue del archivo en la aplicación. Como lo muestra la figura 3, luego de aplicar el instrumento a todos los cursos de la materia cálculo diferencial, se genera un archivo separado por comas que contiene los datos personales, académicos con el estilo de aprendizaje de cada estudiante. Este archivo se carga en el aplicativo de Estilo de Aprendizaje, durante el proceso de carga se valida que no exista estudiantes duplicados que fueron procesados en un archivo anterior o en un semestre pasado.

Figura 3. Cargue de archivos

The screenshot shows a software window titled 'Estilos de Aprendizaje' with a menu bar containing 'Cargue', 'Procesamiento', and 'Modelo'. The active window is 'Cargue de Archivos'. It features a text input field for 'Nombre Archivo' containing 'Estudiantes201402', a text input for 'Año' with '2014', a dropdown menu for 'Semestre' showing '02', and a text input for 'Ruta Archivo' with 'D:/TRABAJO/INVESTIGACION/2014/TEST/201402.xls'. There are 'Buscar' and 'Cargar' buttons.

Fuente. Autores del proyecto

Validar las nuevas instancias con el modelo. Con el archivo cargado, se procesan los registros que contiene, realizando un proceso de discretización de la información en donde se concentra la dimensionalidad¹ de los atributos, con el ánimo de mejorar los resultados (Rodríguez Rodríguez, 2010). Este proceso genera un nuevo archivo que contiene la información del estudiante y su estilo de aprendizaje. El archivo se procesa identificando las características del estudiantes con el histórico de los resultados de obtenidos en los cursos durante los semestres pasados por otros estudiantes. La finalidad es predecir cuál será el rendimiento del estudiante en la materia que está próximo a cursar.

Generar listado de estudiantes con su predicción. Una vez se analizan los nuevos registros procesados con respecto al modelo definido, se produce la predicción en la cual para cada estudiante se le establece el valor de la clase, la cual solo puede tener dos valores de Aprobar o Reprobar: indicado que el estudiante puede o no aprobar la materia. La figura 4, muestra el listado que sirve como insumo para identificar a los estudiantes que poseen características semejantes a los que perdieron la materia en el pasado.

¹ Se considera como el número de posibles valores que pueda tener un atributo.

Figura 4. Integración de resultados

| Codigo | Nombre | Programa | Semestre | Prediccion |
|--------|---------------------------|------------------|----------|------------|
| 274476 | MELO GONZALEZ MA... | INGENIERIA CIVIL | 4 | REPRUEBA |
| 274482 | LOPEZ GONZALEZ MA... | INGENIERIA CIVIL | 4 | APRUEBA |
| 274483 | MORALES GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274487 | VALDERRAMA GONZALEZ MA... | INGENIERIA CIVIL | 3 | APRUEBA |
| 274490 | CRISTINA GONZALEZ MA... | INGENIERIA CIVIL | 2 | APRUEBA |
| 274493 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | APRUEBA |
| 274499 | PEREZ RAMOS MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274500 | GARCIA GONZALEZ MA... | INGENIERIA CIVIL | 3 | APRUEBA |
| 274501 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274502 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274503 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274504 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274505 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274506 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274507 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274508 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274509 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274510 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274511 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 3 | REPRUEBA |
| 274512 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 2 | APRUEBA |
| 274513 | PEREZ GONZALEZ MA... | INGENIERIA CIVIL | 2 | REPRUEBA |

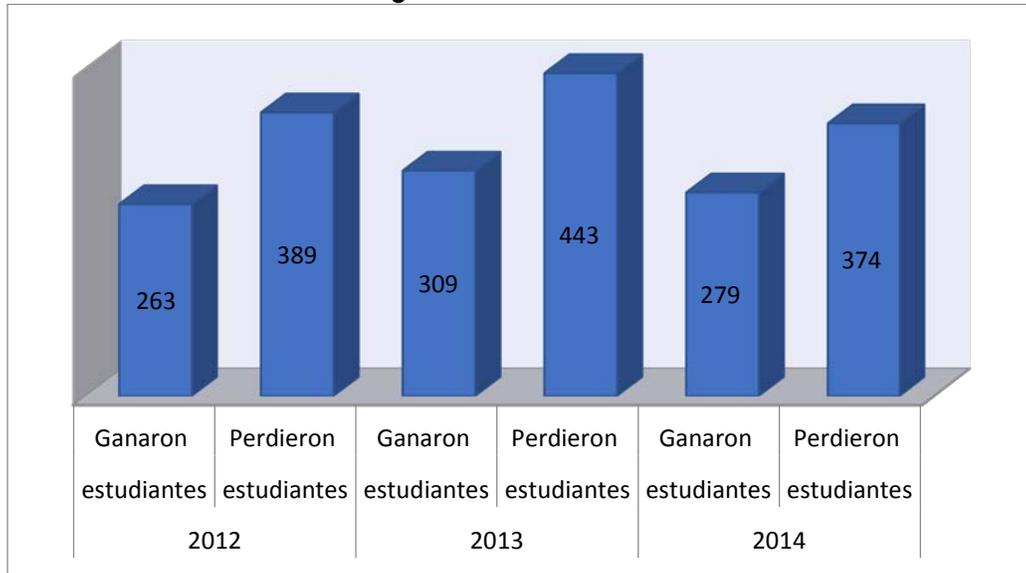
Fuente. Autores del proyecto

Generar un nuevo modelo con las nuevas instancias. Con el ánimo que el modelo de predicción generado, incluya la mayor cantidad de registros que identifiquen los comportamientos de los estudiantes; al finalizar cada semestre el modelo es vuelto a generar con los resultados obtenidos por los estudiantes en la materia, este proceso pretende mejorar el porcentaje de acierto en la predicción que hace el modelo.

Con la información generada por la aplicación, el Departamento de Ciencias Básicas, adelanta estrategias para el desarrollo de la asignatura, se realizan actividades de seguimiento y control para docentes y estudiantes. En el seguimiento que se hace a los docentes en el cumplimiento de los contenidos programáticos, para garantizar las competencias de los estudiantes en esta área de formación, se implementó realizar el examen final de manera simultánea a los estudiantes. De manera adicional, para los estudiantes se realizaron asesorías académicas, durante el semestre académico en donde ellos cuentan con un espacio en el cual reciben explicación de las unidades temáticas de la asignatura en la cual presenten mayor debilidad, esta estrategia busca fortalecer los procesos de aprendizaje, en este caso se asignaron monitores para la asignatura, teniendo en cuenta agrupar a los estudiantes de acuerdo a los estilos de aprendizaje detectados.

En la figura 5, se muestra como fue el comportamiento de los estudiantes en los últimos tres años. Si bien el proceso de captura, tratamiento y predicción del rendimiento académico fue implantado durante el 2014, de los 653 estudiantes que cursaron la asignatura de cálculo diferencial aprobó el 43 % de la población estudiantil.

Figura 5. Resultado finales



Fuente. Autores del proyecto

Dentro del seguimiento realizado a la implantación de la aplicación como mecanismo de seguimiento y clasificación se encontró que una de las razones de la poca disminución del porcentaje de estudiante que reprueba, se debe a que estos solo el 20%, de los estudiantes identificados como candidatos a reprobación, asisten a las asesorías.

5. Conclusiones

Desde los inicios de la humanidad se viene buscando la manera de mejorar y optimizar las actividades diarias de la vida. La educación tampoco es ajena a esta búsqueda y permanentemente es permeada por avances tecnológicos que dinamizan no solo los aspectos académicos, también toca los aspectos administrativos. Con la construcción de la herramienta de identificación de estilos de aprendizaje, se logró almacenar y procesar la información del estudiante que puede permitir predecir cómo será su rendimiento antes de iniciar el curso. Con la información proporcionada por la herramienta se puede hacer un proceso de asesoramiento que permita mejorar los resultados dentro del curso.

La aplicación de materiales de enseñanza basado en la caracterización previa de los estilos de aprendizaje de los estudiantes contribuye al mejoramiento de la calidad del proceso de formación ofreciendo al profesor una solución automática para conocer las preferencias en términos de estilos de aprendizaje de sus estudiantes, y soportando el proceso de generación de diseños instruccionales ajustados a las particularidades de cada estudiante.

El estudio realizado se centró especialmente en proponer elementos enmarcados dentro del proceso de formación, permitiendo entregar diseños de aprendizaje ajustados a las características de los estudiantes, estos, actores principales del proceso

educativo, haciendo uso de técnicas de modelado y creando mecanismos de decisión basados en clasificación automática.

Las consideraciones expuestas permiten ofrecer al docente una solución automatizada para conocer las preferencias en cuanto al estilo de aprendizaje de los estudiantes, factores que podrían ser una herramienta útil para generar diseños instruccionales ajustados a las particularidades de cada alumno.

6. Referencias

- Baumgartner, D., & Serpen, G. (2009). Large Experiment and Evaluation Tool for WEKA Classifiers. *DMIN*, 340-346.
- Castaño Collado, G. (2004). *Independencia de los Estilos de Aprendizaje Desde las Variables Cognitivas y Efectivo Motivacionales*. Madrid: Universidad Complutense de Madrid.
- Cerroni, W., Moro, G., Pirini, T., & Ramilli, M. (2013). Peer-to-peer data mining classifiers for decentralized detection of network attacks. *Proceedings of the Twenty-Fourth Australian Database Conference* (págs. 101-107). Darlinghurst: Hua Wang and Rui Zhang.
- Claxton, C., & Murrell, P. (1987). *Estilos Liaoning: Implicaciones para la Mejora Educativa*. Washington: ERIC.
- Curry, L. (1987). *Integración de Conceptos de Estilo Cognitivo o el Aprendizaje: Una Revisión con Atención a los Estándares Psicométricos*. Ottawa: Canadian College de Ejecutivos de Servicios de Salud.
- Fayyad, U. M., Piatetsky Shapiro, G., Smyth, P., & Uthurusamy, R. (1996). *Advances in Knowledge Discovery and Data Mining*. MIT Press.
- Felder, R., & Brent, R. (2005). *Understanding Student Differences*. *Engineering Education*, 57-72.
- Ferri Ramirez, C., Hernandez Orallo, J., & Ramirez, M. (2004). *Introducción a la Minería De Datos*. Pearson.
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *The Journal of Machine Learning Research* 3, 1157-1182.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. (Junio de 2009). The WEKA data mining software: an update. *ACM SIGKDD Explorations Newsletter*, págs. 10-18.
- Han, J., & Kamber, M. (2006). *Data Mining, Southeast Asia Edition: Concepts and Techniques*. San Francisco: Morgan Kaufmann.
- Hernandez Orallo, J., Ramirez Quintana, M. J., & Ferri Ramirez, C. (2004). *Introducción a la minería de datos*. Madrid: Pearson.
- Honassen, D., & Grabowsky, B. (1993). *Manual de las diferencias individuales y la instrucción*. Newyork.
- Larman, C. (2002). *UML y Patrones*. Madrid: Pearson Educacion, S.A.
- Lichtenwalter, R., & Chawla, N. (11 de Agosto de 2011). LPmade: Link Prediction Made Easy. *Journal of Machine Learning Research*, págs. 2489-2492.
- Marozzo, F., Talia, D., & Trunfio, P. (2013). Scalable script-based data analysis workflows on clouds. *WORKS '13 Proceedings of the eighth Workshop on*

Workflows in Support of Large-Scale Science (págs. 124-133). Denver: ACM New York.

- McCarthy, B. (2011). Desarrollo de un Software Educativo para Identificar Estilos de Aprendizaje y Evaluación de su Impacto en el Aprendizaje. México: Instituto Tecnológico Superior Cajame.
- Quinlan, R. (1989). Unknown attribute values in induction. ML, 164-168.
- Rodríguez Rodríguez, J. E. (2010). Fundamentos de minería de datos (Primera edición ed.). (U. D. Caldas, Ed.) Bogotá, Colombia: Universidad Distrital Francisco José de Caldas.
- SommerVille, I. (2005). Ingenierías de Software Séptima edición. Madrid: Pearson Educación.
- Witten, I. H. (2011). Data Mining: Practical Machine Learning Tools and Techniques. Burlington: Morgan Kaufmann.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). Data Mining: Practical Machine Learning Tools and Techniques (Tercera edición Ed.). Burlington, United States: Morgan Kaufmann Publishers.

Sobre los autores

- **Claudia Marcela Durán Chinchilla.** Licenciada en Lingüística y Literatura, Especialista en Práctica Docente Universitaria; estudios de Doctorado en Educación, y maestría en prácticas pedagógicas. Directora Departamento de Humanidades Facultad de Educación Artes y Humanidades, Investigadora grupo de Investigación GIFEAH. cmduranc@ufpso.edu.co.
- **Alveiro Rosado Gómez.** Ingeniero de Sistemas, Especialista en Gestión de Proyectos Informáticos, Magíster en Gestión Aplicación y Desarrollo de Software, Director del Departamento de sistemas e Informática, Investigador del grupo de investigación GITYD. arosadog@ufpso.edu.co.
- **Malka Irina Cabellos Martínez.** Física, Especialista en Práctica Docente Universitaria, estudios de maestría en Energías renovables Directora del Departamento de Ciencias Básicas, Facultad de Educación Artes y Humanidades, Investigadora grupo de Investigación GIFEAH. micabellosm@ufpso.edu.co.

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2015 Asociación Colombiana de Facultades de Ingeniería (ACOFI)