

LA MEJORA DEL APRENDIZAJE EN AVAs APLICANDO ANALÍTICA DEL APRENDIZAJE

Delia Esther Benchoff, Ivonne Gellon, Carlos Guillermo Lazurri, Constanza R. Huapaya, Erik Borgnia Giannini y Matias H. Gutierrez

Grupo de Investigación Inteligencia Artificial aplicada a Ingeniería / Departamento de Informática/
Facultad de Ingeniería/ Universidad Nacional de Mar del Plata

Juan B. Justo 4302, Mar del Plata, Buenos Aires, Argentina.

{ebenchoff, guillermol, ivonne}@fi.mdp.edu.ar

constanza.huapaya@gmail.com, {eborgnia, mhgutierrez}@alumnos.fi.mdp.edu.ar

RESUMEN

Los ambientes virtuales de aprendizaje (AVAs), reúnen gran cantidad de datos sobre los estudiantes, los cuales son difíciles de analizar manualmente, por lo que se necesitan herramientas y métodos que contribuyan a explorar y aprovecharlos en pos de mejorar el aprendizaje de los usuarios. La Analítica del Aprendizaje (AA) se enfoca en la toma de decisión apoyada en datos, e integra las dimensiones técnicas y pedagógicas del aprendizaje mediante la aplicación de modelos predictivos. Con los avances de AA, especialmente de las técnicas de Machine Learning, puede mejorarse la personalización y adaptación del aprendizaje en AVAs. Los aspectos a enriquecer en la adaptación son: estilos de aprendizaje, estados cognitivos, evaluaciones de proceso y finales, retroalimentación y materiales instruccionales. Las universidades buscan predecir el rendimiento de los estudiantes para minimizar el abandono de sus estudios. La exploración de la personalización avanzada será usada para indagar y corregir las fallas académicas.

Palabras claves: Aprendizaje Personalizado, Analítica del Aprendizaje, Ambiente Virtual de Aprendizaje, Ingeniería Informática.

CONTEXTO

Nuestra línea de I/D está inserta en el proyecto *Mejora del aprendizaje personalizado aplicando analítica del aprendizaje* (ING656/22), el cual continua y profundiza las indagaciones ya iniciadas en los proyectos anteriores denominados: *Adaptación en un*

ambiente virtual de aprendizaje: pruebas y materiales personalizados (ING464/16) y *Personalización en un ambiente virtual de aprendizaje basada en estilos, conocimiento previo y errores frecuentes* (15H27/PSI/19). El primero contribuyó con el diseño y desarrollo de materiales de estudio y pruebas personalizadas para estudiantes universitarios, y en el segundo se emplearon los recursos adaptativos que provee el LMS Moodle, para diseñar itinerarios de aprendizaje, materiales de estudio y actividades personalizadas, que respondan a las características diagnosticadas de los estudiantes.

1. INTRODUCCIÓN

El aprendizaje personalizado explora itinerarios de aprendizaje a la luz de las diferencias personales de los estudiantes considerando su conocimiento y habilidades [1] [2]. Se entiende por itinerarios (o trayectorias) de aprendizaje a cualquier secuencia de contenidos pedagógicos construidos con la finalidad de alcanzar los objetivos de aprendizaje de los estudiantes en un tema o área específica.

En este contexto, los parámetros de la personalización son las variables utilizadas para determinar las características y necesidades de los estudiantes. Los parámetros más usados son objetivos de aprendizaje, conocimiento previo, estilo de aprendizaje, habilidades adquiridas y el tiempo requerido para alcanzar cada objetivo.

Desde el inicio de la carrera Ingeniería Informática, se ha estudiado y desarrollado,

con un esfuerzo sostenido, la personalización de diseños instruccionales, y su adaptación progresiva en AVAs. Durante los primeros años, como complemento de las clases presenciales y de acceso opcional para los estudiantes, a partir de marzo de 2020, a raíz del aislamiento ocasionado por el SAR-COV2, se estableció la modalidad virtual con acceso obligatorio, en 2022 como complemento de las clases presenciales y con acceso obligatorio para todos los estudiantes. Fundamentos de la Informática, ha sido la materia sobre la cual se logró un mayor avance en la personalización y adaptación en el AVA (materiales de estudio, actividades y pruebas formativas), reportando los resultados obtenidos en congresos vinculados a la temática [3] [4]. La gran cantidad de datos existentes actualmente, generados por la actividad en los AVAs (p.e. resultados de encuestas sobre conocimiento previo y aspectos de la cursada, resultados de calificaciones formativas y finales, tiempo de realización de actividades y evaluaciones, estadísticas sobre la dificultad o no de los temas evaluados), particularmente a partir de 2020, demanda la aplicación de métodos y técnicas que brinden conocimiento automático para el diseño de nuevas recomendaciones, las cuales impactarían en la diversificación de los itinerarios de aprendizaje. En otras palabras, la aplicación de algoritmos de software para predecir y/o detectar aspectos desconocidos del proceso de aprendizaje, basados en datos históricos y el comportamiento actual de los estudiantes dentro del entorno en el cual sucede, posibilitarían el progreso de la personalización de los diseños instruccionales y su adaptación en AVAs.

La experiencia acumulada a lo largo de 8 años de investigación en el tema se ha trasladado a 3 materias específicas en la formación del Ingeniero Informático: Programación I. Taller de programación I y Programación III [6].

El aprendizaje personalizado [1] [5] [7] responde al modelo de enseñanza centrado en los estudiantes.

Los ambientes computacionales de aprendizaje tienen que contemplar la adaptación entendida como la adecuación de los contenidos o visualización del sistema a las preferencias del usuario. El proceso de adaptación está basado en las preferencias y objetivos del estudiante. Estas propiedades están almacenadas en el modelo del usuario. Estos modelos brindan la posibilidad de distinguir la intervención de los diferentes actores de la comunidad educativa, y proveer al sistema de la habilidad de adecuar su reacción con datos del modelo del usuario [9]. En el contexto del e-learning, los sistemas adaptativos se enfocan en la presentación de estos contenidos, ajustándose a diferentes condiciones. En los ambientes de aprendizaje se puede distinguir dos tipos de ajustes. En primer lugar, hay sistemas adaptables que pueden cambiar sus parámetros cuando el usuario modifica al sistema de acuerdo a sus necesidades. En segundo lugar, los sistemas adaptativos implican adecuar automáticamente el sistema al usuario. Las necesidades del usuario son inferidas por el sistema, a través de la observación de su comportamiento, cuando éste lo cambia de acuerdo a sus necesidades [8].

Si bien la personalización ha avanzado en estos años [1] [10] [11], el aprendizaje personalizado y su adaptación en AVAs todavía necesita progresar en diversos aspectos como recomendaciones individualizadas, filtrado de contenidos, fidelidad de los estilos de aprendizaje, evaluaciones personalizadas y trabajo colaborativo.

Una posible respuesta en pos de la mejora del aprendizaje personalizado, se basa en la aplicación de Analítica de Datos (AD) [12]. AD comprende una colección de datos valiosos, el análisis inteligente de la información y el hallazgo de conocimiento útil para la toma de decisiones. i.e., una grandes conjuntos de datos, técnicas estadísticas y modelos predictivos. La AD es un campo donde interactúan diferentes disciplinas, como estadística, reconocimiento de patrones, teoría

de sistemas, investigación operativa e Inteligencia Artificial.

En el campo de la educación, la Analítica de Datos dio lugar a la Analítica del Aprendizaje (AA). Desde que AA fue mencionada por primera vez en el reporte de New Media Consortium (NMC) Horizon Report 2012 [13] ha ganado una relevancia creciente. AA se define como la medición, colección, análisis y reporte de datos sobre estudiantes y sus contextos para entender y optimizar el aprendizaje y los ambientes donde ocurre.

Siguiendo a Campbell y Oblinger [14], AA consta de un proceso de 5 pasos: *Captura*, *Reporte*, *Predicción*, *Actuación* y *Refinamiento*.

AA posee cierta semejanza con EDM (Educational Data Mining). Ambas comunidades de investigación analizan información educacional, típicamente recopilada en plataformas en línea. La primera se centra en proveer herramientas para la intervención humana mientras que la segunda considera una adaptación automática.

El propósito de AA es crear un ambiente de aprendizaje amigable y personalizado para los estudiantes y facilitar recomendaciones a fin de alcanzar sus logros. Uno de los beneficios más importantes es el aporte sobre el desempeño de los actores de la comunidad educativa no solo en un momento específico, sino también sobre sus futuros logros o fallas p.e., provee a los estudiantes, docentes y autoridades información sobre su desempeño con relación a otros, identifica estudiantes que necesiten ayuda extra, ayuda a docentes con su planificación de sus cursos, entre otras. Estas metas necesitan un modelo de clasificación y predicción a fin de actuar con acciones remediabiles. Es aquí donde las técnicas de Machine Learning (ML) han mostrado su utilidad [15] [16].

ML es una convergencia de la estadística y las ciencias de la computación donde las máquinas

aprenden a mejorar el rendimiento desde sus experiencias previas, de una manera similar a los humanos. La única diferencia es que las computadoras aprenden desde los datos y las personas aprenden desde sus experiencias. [17].

Algunos autores han establecido que los métodos de aprendizaje de ML (p.e., ANNs (redes neuronales artificiales), SVM (support vector machines) y árboles de decisión pueden ser superiores a sus contrapartes estadísticas (p.e., regresión logística y análisis discriminante) en términos de ser menos restrictivos en sus asunciones y la producción de mejores resultados en sus predicciones. [18].

Las ANNs [19] [20] son herramientas usadas para análisis de datos cuando existen relaciones funcionales entre variables que luego son modeladas, su ventaja es que se pueden aplicar a estudios en los cuales los datos de entrada son incompletos o ambiguos por naturaleza. El estudio del desempeño académico ha ganado gran significancia no sólo para alcanzar un alto nivel, sino en la búsqueda de factores que influyen el proceso educativo [21] [22]. Por ejemplo, para detectar estudiantes en riesgo de abandono de sus estudios, o para reconocer estilos de aprendizaje de estudiantes individualmente de acuerdo a las acciones que ha ejecutado en un AVA [23].

2. LÍNEAS DE INVESTIGACIÓN Y DESARROLLO

- Personalización y adaptación del aprendizaje en AVAs como complemento de clases presenciales y propuestas de modalidad mixta (presencial y remota)
- Identificación de estilos de aprendizaje como aportes al diseño y desarrollo de propuestas formativas personalizadas.
- Analítica del Aprendizaje, exploración e implementación de modelos para la detección de estudiantes en riesgo de abandono, o para reconocer estilos de

aprendizaje de estudiantes individualmente de acuerdo a las acciones que ha ejecutado en un AVA.

3. RESULTADOS OBTENIDOS/ESPERADOS

- Aplicar la experiencia acumulada por el grupo de investigación en personalización y adaptación en AVAs a 4 asignaturas de la carrera Ingeniería Informática.
- Ampliar la base de estilos de aprendizaje para evaluar la permanencia y/o cambio en los estilos y mejorar la adaptación de AVAs.
- Implementar Analítica del Aprendizaje en AVAs para mejorar la personalización y adaptación del aprendizaje.

4. FORMACIÓN DE RECURSOS HUMANOS

El equipo de investigación está compuesto por cuatro docentes investigadores especialistas en educación e informática, y por dos estudiantes avanzados de la carrera Ingeniería Informática en etapa de formación como investigadores.

5. BIBLIOGRAFÍA

- [1] Nabizadeh A. H., Leal J.P., Rafsanjani H.N. y Shah R.R. Learning path personalization and recommendation methods: A survey of the state-of-the-art. *Expert Systems with Applications*. vol. 159. 2020. 113596. ISSN: 0957-4174. <https://doi.org/10.1016/j.eswa.2020.113596>.
- [2] Zhang L., Basham J. D. y Yang S. Understanding the implementation of personalized learning: A research synthesis. *Educational Research Review*. vol. 31. 2020. 100339. ISSN: 1747-938X. <https://doi.org/10.1016/j.edurev.2020.100339>
- [3] González M. P., Benchoff D. E., Huapaya C. R., Remón, C., Lazurri, G., Guccione L., Lizarralde F. A. J. Avances en la

Personalización y Adaptación de Pruebas en un Ambiente Virtual de Aprendizaje. XXIV Congreso Argentino de Ciencias de la Computación. Octubre 2018. pp. 193-202. ISBN: 978-950-658472-6. <http://sedici.unlp.edu.ar/handle/10915/73088>

[4] Benchoff D. E., Lizarralde F. A. J., Huapaya C. R., Aguiar A. L., González M. P. Impacto del COVID19 en la enseñanza personalizada. XVI Congreso de Tecnología en Educación & Educación en Tecnología (TE&ET 2021): libro de actas, Argentina: Facultad de Informática (UNLP). 2021. pp. 61-69. ISBN 978-950-34-2014-0. <http://sedici.unlp.edu.ar/handle/10915/121569>

[5] Mansur A. B. F., Yusof N. and Basori A. H. Personalized Learning Model Behaviour based on Deep Learning Algorithm for Student Behaviour Analytic. *Procedia Computer Science* 16. 2019. pp. 125–133. ISSN 1877-0509. <https://doi.org/10.1016/j.procs.2019.12.094>

[6] Benchoff, D., Lazzurri, C., Gellon, I., Borgnia Gianini, E., González, M., Huapaya, C., and Dai Pra, A. (2022). Personalización y adaptación del aprendizaje en Ingeniería Informática. *Memorias De Las JAIIO*, 8(8), 145-157. Recuperado a partir de <https://publicaciones.sadio.org.ar/index.php/JAIIO/article/view/414>

[7] Chrysafiadi K., Virvou M. *Advances in Personalized Web-Based Education*. e-Book. Springer Cham Heidelberg. 201. ISBN 978-3-319-12895-5

[8] Froschl C. *User Modeling and User Profiling in Adaptive E-learning Systems*. Master's Thesis de la Graz University of Technology. (2005)

[9] Brusilovsky P. y Maybury M.T. From adaptive hypermedia to the adaptive web. *Communications of the ACM*. 2002. e-Book, vol. 45, no. 5 pp. 30–33. DOI: 10.1145/506218.506239

- [10] Tian F., Zheng Q., Gong Z., Du J. and Li R. Personalized Learning Strategies in an intelligent e-Learning Environment. 2007 11th International Conference on Computer Supported Cooperative Work in Design, 2007, pp. 973-978, doi: 10.1109/CSCWD.2007.4281570
- [11] Benchoff D. E., González M. P. and Huapaya C. R. Personalization of Tests for Formative SelfAssessment. in IEEE Revista Iberoamericana de Tecnologías del Aprendizaje, vol. 13, no. 2, pp. 70-74, May 2018, doi: 10.1109/RITA.2018.2831759
- [12] Wibawa B., Siregar J. S., Asrorie D. A. and Syakdiyah H. Learning Analytic and Educational Data Mining for Learning Science and Technology. The 2nd Science and Mathematics International Conference (SMIC 2020) AIP Conf. Proc. 2331, 060001-1–060001-7; <https://doi.org/10.1063/5.0041844> Published by AIP Publishing. 978-0-7354-4075-3.
- [13] Johnson L., Adams S., Cummins M., The NMC horizon report: 2012 higher education-edition. The New Media Consortium, Austin. 2012
- [14] Campbell J.P., DeBlois PB, Oblinger DG Academic analytics: a new tool for a new era. EDUCAUSE Review 42 Vol. 4. 2007. pp. 40–57. <https://er.educause.edu/articles/2007/7/academic-analytics-a-newtool-for-a-new-era>
- [15] Mitchell T. Machine Learning. New York, McGraw Hill. 1997. ISBN OCLC 36417892.
- [16] Mitchell T. Cap. 14 Key Ideas in Machine Learning. DRAFT OF December 4, 2017
- [17] Bishop, C. M., Pattern recognition and machine learning. Book. Springer. 2006. ISBN 978-0-387-310732
- [18] Delen D. A. Comparative analysis of machine learning techniques for student retention management. Decision Support Systems 49 (2010) 498–506.
- [19] Rumelhart, D.E.; James McClelland. Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Cambridge: MIT Press. Book. 1987. <https://ieeexplore.ieee.org/servlet/opac?bknumber=627682>
- [20] Bouwmans, T., Javed, S., Sultana, M., and Jung, S. K. Deep neural network concepts for background subtraction: A systematic review and comparative evaluation. Neural Networks, Vol. 117. 2019. pp. 866. ISSN 0893-6080. <https://doi.org/10.1016/j.neunet.2019.04.024>
- [21] Mason, C., Twomey, J., Wright, D., and Whitman, L. Predicting Engineering Student Attrition Risk Using a Probabilistic Neural Network and Comparing Results with a Backpropagation Neural Network and Logistic Regression. Res. High. Educ. Vol. 59, pp. 382–400. 2018. doi: 10.1007/s11162-017-9473-z
- [22] Figueiredo, J., Lopes, N., and García-Pévalo, F. J. Predicting student failure in an introductory programming course with multiple back-propagation. ACM Int. Conf. Proc. Ser. 2019, pp. 44–49. 2019. doi: 10.1145/3362789.3362925
- [23] Villaverde J. E., D. Godoy and Amandi A. Learning styles' recognition in e-learning environments with feed-forward neural networks. June 2006. Journal of Computer Assisted Learning 22(3):197-206. doi: 10.1111/j.1365-2729.2006.00169.x