



DE LA PREDICCIÓN A LA ACCIÓN: VISUALIZACIÓN DE RIESGO ACADÉMICO PARA FORTALECER LA RETENCIÓN ESTUDIANTIL EN EDUCACIÓN SUPERIOR

Alejandro Arias, Pontificia Universidad Católica de Chile
Juan Andrés Talamás, Tecnológico de Monterrey, México
Isabel Hilliger, Pontificia Universidad Católica de Chile
Héctor G. Ceballos, Tecnológico de Monterrey, México

RESUMEN

- La deserción en educación superior representa uno de los desafíos más críticos en América Latina, donde altas tasas de abandono impactan tanto la equidad educativa como el desarrollo de los países de la región. Frente a este escenario, han emergido modelos predictivos basados en algoritmos de aprendizaje de máquinas (*machine learning*) capaces de identificar tempranamente a estudiantes en riesgo. Sin embargo, si bien existe una creciente base investigativa sobre estos enfoques, se sabe poco acerca de cómo sus resultados pueden orientar el diseño de intervenciones oportunas y efectivas para mejorar la retención estudiantil. Este Policy Brief aborda esa brecha a partir de

un estudio piloto desarrollado en dos carreras de la Facultad de Ingeniería de la Pontificia Universidad Católica de Chile, en colaboración con el Tecnológico de Monterrey. El estudio exploró el uso de Inteligencia Artificial Explicable (XAI) —específicamente el método SHAP aplicado sobre el algoritmo XGBoost— para generar visualizaciones comprensibles del riesgo de deserción estudiantil. Los resultados fueron evaluados mediante la técnica de paseo cognitivo con profesionales del programa institucional de alertas académicas, quienes valoraron positivamente la utilidad del sistema para priorizar intervenciones y fortalecer el acompañamiento estudiantil en educación superior.

METODOLOGÍA

- Se realizó un análisis cuantitativo de datos históricos de 4.951 estudiantes de dos carreras de ingeniería de la Pontificia Universidad Católica de Chile, con registros entre 2019 y 2024. Los datos incluyen 20 variables socioeconómicas y académicas, y fueron utilizados para construir un modelo de predicción de riesgo de deserción estudiantil.
- El modelamiento predictivo se desarrolló mediante el algoritmo XGBoost, ampliamente utilizado en contextos de minería de datos educativos por su rendimiento y robustez. Para hacer interpretables sus predicciones, se aplicó el método SHAP (SHapley Additive ExPlanations), que permite visualizar la contribución de cada variable al riesgo individual de un estudiante, generando dos tipos de gráficos: de cascada (nivel individual) y de enjambre (nivel global).
- La evaluación del sistema de visualización se realizó con cinco profesionales que participan activamente en el programa institucional de alertas académicas. La instancia incluyó entrevistas grupales y paseos cognitivos (Cognitive Walkthrough) con casos reales anonimizados, con el objetivo de valorar la utilidad y usabilidad del sistema para orientar intervenciones de acompañamiento estudiantil.
- Los datos cualitativos fueron codificados y triangulados por el equipo investigador, y los instrumentos fueron validados mediante juicio experto, asegurando el rigor metodológico del estudio.

Para citar: Arias, A., Talamás, J. A., Hilliger, I., & Ceballos, H. G. (2026). *De la predicción a la acción: Visualización de riesgo académico para fortalecer la retención estudiantil en educación superior*. (CEPPE Policy Briefs, N°45). Centro UC de Estudios de Políticas y Prácticas en Educación. Disponible en <https://ceppe.uc.cl/images/contenido/policy-briefs/ceppe-policy-brief-n45.pdf>

PRINCIPALES RESULTADOS

- Los orientadores y tutores del programa de alertas académicas gestionan grandes volúmenes de estudiantes, lo que exige organizar sus actividades a partir de la descarga y análisis de datos provenientes de plataformas institucionales. En este contexto, las visualizaciones predictivas representan un avance significativo, al permitir anticipar necesidades y priorizar casos de manera más eficiente y fundamentada.
- Los participantes valoraron positivamente el sistema de visualización como apoyo para la toma de decisiones. En particular, destacaron su utilidad para identificar patrones relevantes en el comportamiento estudiantil, percibir el impacto cuantificable de las decisiones de acompañamiento, agilizar entrevistas con estudiantes según su nivel de riesgo y adaptar estrategias de contacto con recomendaciones más integrales.
- Se identificaron dos limitaciones principales en el uso del sistema: por un lado, una sobrecarga visual en los gráficos — especialmente en el uso de etiquetas, colores e indicadores de riesgo— que dificultó la interpretación autónoma; por otro, limitaciones en la capacidad de los profesionales para interpretar de forma independiente los resultados del modelo sin acompañamiento.
- A nivel institucional, el sistema potencia la priorización del acompañamiento de estudiantes en alerta académica, así como el diseño de intervenciones grupales basadas en variables que favorezcan la retención. Esto abre la posibilidad de articular acciones coordinadas entre direcciones de docencia y asuntos estudiantiles, trascendiendo el alcance del programa de alertas tradicional.
- La priorización que habilita el sistema permite además retroalimentar el diagnóstico institucional sobre el perfil de los estudiantes en riesgo, facilitando la continuidad de los procesos de acompañamiento e incorporando a quienes, pese a no participar actualmente en dichos programas, presentan señales de deserción identificables mediante el modelo predictivo.

RECOMENDACIONES

- Simplificar la nomenclatura del sistema de visualización, distinguiendo de manera explícita entre variables académicas y no académicas, y acompañando los gráficos con descripciones breves que faciliten su interpretación por parte de equipos no especializados en análisis de datos.
- Integrar el sistema en las plataformas y flujos institucionales existentes, articulando su uso con los procesos y tiempos que ya estructuran el trabajo de los equipos de acompañamiento, para reducir la fricción de adopción.
- Validar las variables del modelo con literatura científica sobre deserción y rendimiento académico, fortaleciendo la credibilidad del sistema ante los profesionales que lo utilizan y mejorando la pertinencia de las predicciones generadas.
- Desarrollar una tipología de intervenciones basada en las variables del modelo y su importancia relativa, aprovechando la capacidad del algoritmo de aprendizaje de máquinas para jerarquizar factores de riesgo y orientar respuestas diferenciadas según el perfil de cada estudiante.
- Habilitar el seguimiento longitudinal de los estudiantes, permitiendo monitorear su trayectoria más allá del momento puntual de la alerta y evaluar el impacto de las intervenciones realizadas.
- Complementar la predicción de riesgo con información sobre factores protectores de cada estudiante, enriqueciendo el diagnóstico y orientando intervenciones más integrales y pertinentes.
- Acompañar la implementación del sistema con formación continua de los equipos en interpretación de datos y visualizaciones, condición necesaria para superar las barreras de adopción identificadas en el estudio.

1. INTRODUCCIÓN

En las últimas décadas, la educación superior en América Latina ha experimentado una expansión significativa de su matrícula, impulsada por políticas de acceso orientadas a incorporar a estudiantes de sectores históricamente excluidos. En Iberoamérica, la matrícula creció un 42% entre 2010 y 2021, mientras que en Chile este aumento alcanzó un 184% en el mismo período (Centro Interuniversitario de Desarrollo, 2024). Este crecimiento plantea desafíos institucionales relevantes en términos de graduación oportuna y eficiencia, siendo la deserción estudiantil uno de los principales obstáculos, pues no solo afecta los indicadores institucionales, sino también las trayectorias personales y profesionales del estudiantado (Doray & Groleau, 2020; OECD, 2024).

La evidencia internacional ha identificado múltiples factores asociados a la deserción en educación superior: nivel socioeconómico, capital sociocultural, brechas académicas de entrada, falta de beneficios económicos y distancia geográfica al centro educativo, entre otros (Kocsis & Molnár, 2025). En respuesta, diversas instituciones han implementado estrategias de apoyo a la retención estudiantil. Por ejemplo, el sistema “AssessMe”¹ del Rochester Institute of Technology en Croacia, para predecir resultados académicos temprano y permitir intervenciones con un 93% de precisión de aprobación o reprobación a la quinta semana de un semestre quince semanas. En Purdue University en Estados Unidos, es otro ejemplo temprano de analíticas predictivas aplicadas a la retención estudiantil. Su sistema computarizado “CourseSignals”² analiza más de 20 indicadores de esfuerzo académico —como uso de materiales en línea, asistencia a tutorías y calificaciones parciales— para predecir el desempeño de cada estudiante y mostrarle una señal tipo semáforo (roja, amarilla o verde) junto con mensajes personalizados del profesor sobre cómo mejorar, logrando en estudios piloto que el 67% de los estudiantes con alerta amarilla o roja mejorara su esfuerzo y calificaciones. Es así como se ha destacado el aumento del uso de técnicas de aprendizaje de máquinas (*machine learning*) para el análisis masivo de datos educativos, permitiendo identificar tempranamente a estudiantes en riesgo de deserción a partir de variables académicas y socioeconómicas, abriendo nuevas posibilidades para el diseño de intervenciones preventivas (Kocsis & Molnár, 2025).

Sin embargo, la sofisticación de algunos de estos modelos genera predicciones difíciles de interpretar para quienes deben actuar sobre ellas: orientadores, tutores y equipos de gestión académica. Este problema —denominado ‘caja negra’— limita la confianza en el sistema y, por ende, su utilidad práctica en los procesos institucionales de acompañamiento estudiantil (Nazar et al., 2021). Surge así la necesidad de enfoques de Inteligencia Artificial Explicable (*Explainable Artificial Intelligence, XAI*), como el método SHAP (*SHapley Additive ExPlanations*), que permiten visualizar la contribución individual de cada variable al riesgo predicho y orientar intervenciones concretas basadas en evidencia.

En este contexto, el presente Policy Brief busca contribuir a cerrar la brecha entre la predicción y la acción, presentando los hallazgos de un estudio piloto desarrollado en dos carreras de la Facultad de Ingeniería de la Pontificia Universidad Católica de Chile, en colaboración con el Tecnológico de Monterrey. A partir de la aplicación de

XAI sobre un modelo predictivo de deserción y su evaluación con profesionales del programa institucional de alertas académicas, el documento identifica las condiciones que favorecen el uso de visualizaciones de riesgo para priorizar y diseñar intervenciones de acompañamiento estudiantil, con el propósito de ofrecer orientaciones concretas para vicerrectorías académicas y equipos de gestión en educación superior.

2. MODELOS PREDICTIVOS Y EL DESAFÍO DE LA CAJA NEGRA

El uso de técnicas de aprendizaje de máquinas para predecir la deserción estudiantil ha crecido significativamente en la última década. Según Kocsis y Molnár (2025), los métodos más utilizados en educación superior incluyen el *Educational Data Mining* y la modelación de ecuaciones estructurales, con técnicas como árboles de decisión, regresión logística y redes neuronales. Las variables más influyentes en estos modelos suelen ser el promedio de calificaciones, los créditos obtenidos y el género. Estas herramientas permiten a las instituciones anticipar situaciones de riesgo y focalizar sus recursos de acompañamiento de manera más eficiente.

Sin embargo, la creciente sofisticación de estos algoritmos ha intensificado el denominado problema de la ‘caja negra’: la dificultad de comprender cómo se generan las predicciones limita la transparencia del sistema y reduce la confianza de quienes deben actuar sobre sus resultados (De Oliveira et al., 2021). Para orientadores, tutores y equipos de gestión académica, recibir una predicción de riesgo sin una explicación comprensible de sus factores determinantes resulta insuficiente para diseñar intervenciones pertinentes. Este desafío no es menor: sin interpretabilidad, los modelos predictivos corren el riesgo de convertirse en herramientas subutilizadas o ignoradas en la práctica institucional.

Frente a este problema, la Inteligencia Artificial Explicable (*Explainable Artificial Intelligence, XAI*) ha emergido como un enfoque prometedor. Métodos como SHAP (*SHapley Additive ExPlanations*) permiten visualizar la contribución individual de cada variable al riesgo predicho, haciendo comprensibles las predicciones tanto a nivel individual como global. Existen experiencias destacadas en esta dirección en países como Italia (Agrusti et al. 2020; Gitto et al. 2016), Alemania (Heublein, 2014) y Túnez (Srairi, 2024), así como iniciativas relevantes en Norteamérica —como el uso de datos para promover la equidad en la University of California Berkeley (UCLA School of Education & Information Studies, 2026) y la creación del Data Hub en el Tecnológico de Monterrey (Alvarado-Urbe et al., 2022)— que ilustran el potencial de estos enfoques cuando se acompañan de herramientas interpretables y se integran en los flujos de trabajo institucionales.

Este Policy Brief se enmarca en el proyecto *Comparing the causes of dropout between Higher Education Institutions in Mexico, Chile and Argentina* using Explainable AI, financiado por el Hemispheric University Consortium (HUC) e iniciado entre 2024 y 2025. El proyecto reúne a la Pontificia Universidad Católica de Chile, el Tecnológico de Monterrey y la Universidad Austral de Argentina, con el objetivo de comparar las causas de deserción entre instituciones de educación

1 Sobre AssessMe: <https://www.rit.edu/croatia/news/assessme-project-recognized-among-europes-top-innovations-higher-education>

2 <https://www.purdue.edu/uns/x/2009b/090827ArnoldSignals.html>

superior de tres países latinoamericanos mediante el uso de XAI. En este marco, el presente estudio piloto constituye uno de los primeros resultados empíricos del proyecto, aportando evidencia sobre cómo las visualizaciones generadas por estos modelos pueden informar el trabajo de los equipos de acompañamiento estudiantil.

3. METODOLOGÍA

El estudio se desarrolló en dos etapas metodológicas complementarias. La primera consistió en el modelamiento predictivo del riesgo de deserción a partir de datos institucionales. Se analizó un conjunto de 4.951 estudiantes de dos carreras de ingeniería de la Pontificia Universidad Católica de Chile, con 20 variables socioeconómicas y académicas registradas entre 2019 y 2024. Sobre estos datos se aplicó el algoritmo XGBoost para generar predicciones individuales de riesgo, y el método SHAP (*SHapley Additive ExPlanations*) para interpretarlas, en línea con enfoques recientes de IA explicable aplicada a la retención estudiantil en educación superior (Talamás-Carvajal et al., 2025). El sistema produce dos tipos de visualizaciones: una vista comparativa global, que permite contrastar el comportamiento de distintas poblaciones estudiantiles —por ejemplo, quienes están

en alerta académica versus quienes no lo están— ordenando las variables según su influencia relativa en cada grupo (ver Figura 1) a través de un gráfico enjambre de abeja o *beeswarm plot*. En el eje Y los valores brutos de las variables en análisis. El eje X contiene los valores SHAP donde el valor cero es el centro y los positivos corresponden a la predicción de deserción. Los colores indican el valor original de la variable siendo el color rojo un valor alto dentro de la variable y azul el color bajo en un continuo de gradiente. El color gris corresponde a valores NaN. La densidad de puntos (el enjambre) representa a cada estudiante en la variable correspondiente, acumulándose horizontalmente.; y una vista individual por carrera, que muestra mediante un gráfico de cascada la contribución específica de cada factor al riesgo de deserción de un estudiante en particular, diferenciando entre variables que aumentan el riesgo y factores protectores, entregando un puntaje de riesgo interpretable (ver Figura 2). Se muestra por tanto en el eje X el riesgo de deserción de las variables del eje Y. El eje Y muestra el valor correspondiente a cada elemento predicho. Se agrega un valor de contribución al riesgo de deserción promedio ($E[f(x)]$) al interior de las barras de color. El riesgo promedio de deserción está informado en la parte izquierda del eje X. El color rojo indica riesgo de deserción y el color azul sin riesgo de deserción para las variables del eje Y.

Figura 1. Vista comparativa global — distribución de variables en población sin alerta y con alerta académica

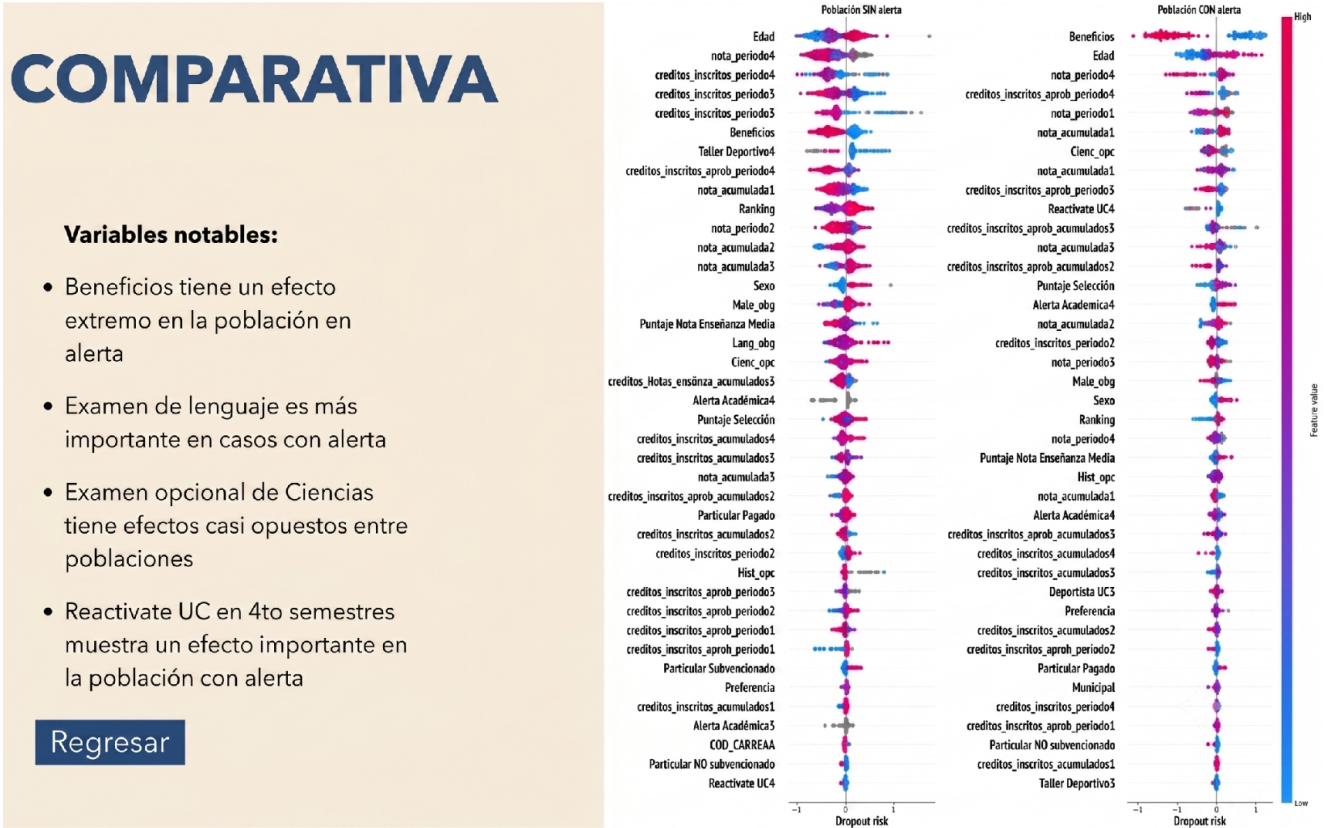



Figura 2. Vista individual — ejemplo Estudiante 117373, Ingeniería Civil [con puntaje de riesgo $f(x) = 2.865$]



La segunda etapa consistió en la evaluación del sistema con profesionales que participan activamente en el programa institucional de alertas académicas de la PUC Chile. Esta instancia se estructuró en tres momentos: una entrevista grupal inicial para caracterizar el proceso institucional de alertas; paseos cognitivos (*Cognitive Walkthrough*) en los que cinco profesionales exploraron el sistema de visualización a partir de tres casos reales anonimizados (Mahatody et al., 2010); y una entrevista grupal de cierre para evaluar la utilidad y usabilidad percibida de la herramienta. Los datos cualitativos fueron codificados y triangulados por el equipo investigador, y los instrumentos fueron validados mediante juicio experto, asegurando el rigor del estudio.

4. PRINCIPALES HALLAZGOS

4.1 GESTIÓN DEL PROCESO DE ACOMPAÑAMIENTO ESTUDIANTIL MEJORADA CON VISUALIZACIONES PREDICTIVAS

Los profesionales del programa de alertas académicas gestionan simultáneamente grandes volúmenes de información de estudiantes, lo que exige organizar sus actividades a partir de la descarga y análisis de datos provenientes de múltiples plataformas institucionales. Este contexto de alta carga de trabajo dificulta la identificación oportuna de estudiantes en situación de riesgo y limita la capacidad de respuesta de los equipos. La incorporación de visualizaciones predictivas representa un avance significativo en este escenario, al permitir anticipar necesidades, jerarquizar casos según su nivel de riesgo y orientar de manera más eficiente las decisiones de intervención, sin depender exclusivamente de procesos manuales de revisión de datos.

Los participantes también valoraron positivamente el sistema como apoyo para la toma de decisiones en el proceso de alertas académicas. En particular, destacaron su capacidad para identificar patrones relevantes en el comportamiento estudiantil que de otro modo resultarían difíciles de detectar en el volumen habitual de información disponible. Se valoró especialmente la posibilidad de agilizar las entrevistas con estudiantes priorizando aquellos con mayor riesgo, adaptar las estrategias de contacto según el perfil de cada caso, y formular recomendaciones de acompañamiento más integrales y fundamentadas. Asimismo, los profesionales reconocieron en el sistema la capacidad de hacer visible el impacto cuantificable de sus decisiones de acompañamiento, lo que fortalece la reflexión sobre la efectividad de las intervenciones realizadas. El acompañamiento guiado durante los paseos cognitivos fue clave para facilitar la comprensión contextualizada de las visualizaciones y generar confianza en el sistema.

4.2 DIFICULTADES DEL SISTEMA DE VISUALIZACIÓN

Se identificaron dos limitaciones principales en el uso del sistema. Por una parte, los gráficos presentaron una sobrecarga visual significativa, especialmente en el uso de etiquetas, la codificación por colores y la presentación del indicador de riesgo, lo que dificultó la interpretación autónoma por parte de los usuarios. Por otra, se observaron limitaciones en la capacidad de los profesionales para interpretar de forma independiente los resultados del modelo, en particular las visualizaciones globales que comparan distintas poblaciones estudiantiles. Ambas dificultades subrayan la importancia de diseñar interfaces centradas en el usuario y de acompañar la

implementación de estas herramientas con procesos de formación en interpretación de datos.

5. CONCLUSIONES

Este estudio demuestra que el uso de Inteligencia Artificial Explicable en educación superior puede escalar institucionalmente para fortalecer los procesos de retención estudiantil. La transformación del modelo predictivo en una herramienta de XAI fue clave para superar el problema de la 'caja negra': la transparencia en la generación de predicciones permitió a los profesionales confiar en el sistema y utilizarlo como apoyo estratégico en la toma de decisiones. Al entregar información accionable y fortalecer el juicio profesional, el sistema no reemplaza la labor humana, sino que la potencia, contribuyendo a una transformación digital inclusiva y basada en evidencia.

A nivel institucional, el sistema muestra un potencial significativo para priorizar el acompañamiento de estudiantes en alerta académica, así como para el diseño de intervenciones grupales basadas en las variables que el modelo identifica como más relevantes para la retención. Esta capacidad de priorización permite además retroalimentar el diagnóstico institucional sobre el perfil de los estudiantes en riesgo, facilitando la continuidad de los procesos de acompañamiento e incorporando a quienes, pese a no participar actualmente en dichos programas, presentan señales de deserción identificables mediante el modelo. En este sentido, el sistema abre la posibilidad de articular acciones coordinadas entre direcciones de docencia y asuntos estudiantiles, promoviendo una gestión más integrada de las trayectorias académicas.

El estudio reveló diferencias significativas entre las dos carreras participantes: una con infraestructura tecnológica robusta que permite un enfoque proactivo, y otra con una gestión más colaborativa y centrada en necesidades emergentes. En ambos casos, el acompañamiento guiado durante los paseos cognitivos permitió superar barreras de comprensión, mejorando la confianza en el sistema. Estos hallazgos subrayan la importancia de considerar las particularidades de cada contexto institucional en el diseño e implementación de herramientas predictivas.

Si bien este estudio piloto se desarrolló en el marco de dos carreras de la Pontificia Universidad Católica de Chile, futuros trabajos en el marco del proyecto financiado por el Hemispheric University Consortium contemplarán enfoques comparativos entre instituciones de México, Chile y Argentina. Estos estudios permitirán identificar variaciones en las causas de deserción según los distintos contextos institucionales y nacionales, e informar el diseño de políticas de retención a partir del intercambio de experiencias y lecciones aprendidas entre las universidades participantes.

REFERENCIAS:

- » Alvarado-Urbe, J., Mejía-Almada, P., Masetto Herrera, A. L., Molontay, R., Hilliger, I., Hegde, V., Montemayor Gallegos, J. E., Ramírez Díaz, R. A., & Ceballos, H. G. (2022b). Student Dataset from Tecnológico de Monterrey in Mexico to Predict Dropout in Higher Education. *Data 2022*, Vol. 7, Page 119, 7(9), 119. <https://doi.org/10.3390/DATA7090119>
- » Agrusti, F., Mezzini, M., & Bonavolontà, G. (2020). Deep learning approach for predicting university dropout: A case study at roma tre university. *Journal of E-Learning and Knowledge Society*, 16(1), 44–54. <https://doi.org/10.20368/1971-8829/1135192>
- » Centro Interuniversitario de Desarrollo. (2024). *Educación Superior en Iberoamérica: Informe 2024*. www.cinda.cl
- » De Oliveira, C. F., Sobral, S. R., Ferreira, M. J., & Moreira, F. (2021). How Does Learning Analytics Contribute to Prevent Students' Dropout in Higher Education: A Systematic Literature Review. *Big Data and Cognitive Computing*, 5(4), 64. <https://doi.org/10.3390/bdcc5040064>
- » Doray, P., & Groleau, A. (2020). First-Generation Student, A Sociohistorical Analysis. En P. N. Teixeira & J. C. Shin (Eds.), *The International Encyclopedia of Higher Education Systems and Institutions*. Springer. https://doi.org/10.1007/978-94-017-8905-9_338
- » Gitto, L., Minervini, L. F., & Monaco, L. (2016). University dropouts in Italy: Are supply side characteristics part of the problem? *Economic Analysis and Policy*, 49, 108–116. <https://doi.org/10.1016/j.eap.2015.12.004>
- » Heublein, U. (2014). Student Drop-out from German Higher Education Institutions. *European Journal of Education*, 49(4), 497–513. <https://doi.org/10.1111/EJED.12097>
- » Kocsis, Á., & Molnár, G. (2025). Factors influencing academic performance and dropout rates in higher education. *Oxford Review of Education*, 51(3), 414–432. <https://doi.org/10.1080/03054985.2024.2316616>
- » Mahatody, T., Mouldi, S., & Kolski, C. (2010). State of the Art on the Cognitive Walkthrough Method. *International Journal of Human-Computer Interaction*, 26(8), 741–785. <https://doi.org/10.1080/10447311003781409>
- » Nazar, M., et al. (2021). A Systematic Review of Human-Computer Interaction and Explainable Artificial Intelligence in Healthcare. *IEEE Access*, 9, 153316–153348. <https://doi.org/10.1109/ACCESS.2021.3127881>
- » OECD. (2024). *Education at a Glance 2024: OECD Indicators*. OECD Publishing.
- » Srairi, S. (2022). An Analysis of Factors Affecting Student Dropout: The Case of Tunisian Universities. *International Journal of Educational Reform*, 31(2), 168–186. <https://doi.org/10.1177/10567879211023123>
- » Talamás-Carvajal, J. A., Ceballos, H. G., & Hilliger, I. (2025). The Facts Behind the Prophecy: Validating a Methodology for Identifying Behavioural Differences in Higher Education Student Subpopulations Under Intervention. *Journal of Learning Analytics*, 12(2), 211–223. <https://doi.org/10.18608/jla.2025.8553>
- » UCLA School of Education & Information Studies. (2026). *UCLA Ed&IS Data Hub*. Regents of the University of California. <https://seis.ucla.edu/about/office-of-justice-equity-diversity-and-inclusion/data-hub/>

ACERCA DE CEPPE-UC

CEPPE UC tiene como misión prioritaria realizar investigación sobre políticas y prácticas en educación, para contribuir al desarrollo del sistema educativo chileno. El Centro busca mejorar la base de evidencia con que la sociedad y las instituciones educativas cuentan para comprender y responder a las demandas educacionales del país.

En particular, CEPPE UC impulsa una amplia agenda de proyectos de investigación, tanto avanzada como aplicada, que abordan problemas estratégicos de la educación chilena desde una perspectiva multidisciplinaria.

ACERCA DE LA SERIE POLICY BRIEFS

Esta serie busca contribuir a la difusión del conocimiento y la promoción del debate educacional entre los actores relevantes. Sus números contienen los principales hallazgos de investigaciones avanzadas y aplicadas realizadas en el Centro desde el año 2010.

Para contribuir al debate educacional en marcha, la serie ofrece al público –tanto masivo como especializado– evidencia acotada y de fácil consulta, en un formato breve y accesible.

La producción académica del Centro es variada y se encuentra disponible en distintos formatos, que se pueden encontrar en el sitio web institucional www.ceppeuc.cl.

OTRAS PUBLICACIONES

Entre ellos destacan:

- Libros Ediciones UC. Colección en Educación CEPPE UC.

La Colección se ha propuesto como objetivo la comunicación de nuevas ideas, hallazgos y evidencias en un lenguaje accesible, para contribuir desde la academia a la discusión y propuestas de políticas públicas en educación.

- Artículos académicos.

CEPPE UC genera investigación educacional de excelencia, publicando en revistas académicas de alto impacto tanto nacionales como internacionales en una gama amplia de áreas y disciplinas de la investigación educacional.



Centro UC

Estudios de Políticas y Prácticas
en Educación - CEPPE

Campus San Joaquín Universidad Católica 3º Piso Edificio Decanato de Educación
Avda. Vicuña Mackenna 4860, Macul, Santiago, Chile Teléfono: (562) 235 413 30 www.ceppeuc.cl



ceppe@uc.cl



[/ceppeuc](https://www.facebook.com/ceppeuc)



[@ceppe_uc](https://twitter.com/ceppe_uc)



[@ceppe_uc](https://www.instagram.com/ceppe_uc)



[CEPPE UC](https://www.linkedin.com/company/ceppe-uc)