

CAMINO HACIA LA INCLUSIÓN EDUCATIVA: 4 PASOS PARA LA CONSTRUCCIÓN DE SISTEMAS DE PROTECCIÓN DE TRAYECTORIAS

PASO 2

¿Cómo diseñar sistemas de alerta temprana?

Desde sistemas basados en
conocimiento experto e indicadores
hasta inteligencia artificial



Elena Arias Ortiz, Cecilia Giambruno, Natalia González Alarcón,
Marcelo Pérez Alfaro, Cristina Pombo y Roberto Sánchez Ávalos



Copyright © [2021] Banco Interamericano de Desarrollo. Esta obra se encuentra sujeta a una licencia Creative Commons IGO 3.0 Reconocimiento-NoComercial-SinObrasDerivadas (CC-IGO 3.0 BY-NC-ND) (<http://creativecommons.org/licenses/by-nc-nd/3.0/igo/legalcode>) y puede ser reproducida para cualquier uso no-comercial otorgando el reconocimiento respectivo al BID. No se permiten obras derivadas.

Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la CNUDMI (UNCITRAL). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID, no están autorizados por esta licencia CC-IGO y requieren de un acuerdo de licencia adicional.

Note que el enlace URL incluye términos y condiciones adicionales de esta licencia.

Las opiniones expresadas en esta publicación son de los autores y no necesariamente reflejan el punto de vista del Banco Interamericano de Desarrollo, de su Directorio Ejecutivo ni de los países que representa.



Este documento está enmarcado dentro de la iniciativa fAIr LAC del Banco Interamericano de Desarrollo (BID) que busca promover el uso ético y responsable de los datos y de los sistemas basados en la IA en la región, especialmente en la provisión de servicios sociales.



Tabla de contenidos

1	Introducción	4
2	¿Qué son los sistemas de alerta temprana?	6
3	Sistemas de alerta temprana como herramienta de soporte de decisiones en política pública	7
	3.1 Conceptualización y diseño	8
	3.2 Recolección y manejo de datos	12
	3.3 Desarrollo del modelo y validación	19
	3.4 Uso y monitoreo	30
	3.5 Rendición de cuentas	33
4	Próximos pasos	34
	Bibliografía	35



1 Introducción

El presente documento constituye el segundo de cuatro pasos de la serie “*Camino hacia la inclusión educativa: 4 pasos para la construcción de sistemas de protección de trayectorias*”. El objetivo de esta serie es constituirse en una guía para ministerios y secretarías de Educación de la región interesadas en el diseño y la implementación de sistemas de protección de trayectorias.

La serie consolida el conocimiento existente sobre la protección de las trayectorias educativas, en un contexto en el que el desafío de la exclusión en América Latina y el Caribe (ALC) es cada vez más extenso. Desde antes de la pandemia de la COVID-19, las tasas de exclusión educativa en ALC eran muy preocupantes. Se estima que el impacto del cierre de las escuelas durante la emergencia sanitaria en términos de exclusión educativa podría alcanzar a más de 3 millones de niños, niñas y jóvenes en la región, desde el nivel preescolar hasta el nivel terciario (UNESCO, 2020), afectando en particular a los más vulnerables (Acevedo et al., 2020). Esto obliga a redoblar esfuerzos para encontrar respuestas sistémicas basadas en la evidencia, mediante el empleo de nuevas tecnologías disponibles.

El objetivo de un sistema de protección de trayectorias es “construir las condiciones, para que los recorridos de las niñas, niños y adolescentes dentro del sistema educativo sean continuos, completos y de calidad, disminuyendo el rezago y el abandono temprano, y generando igualdad de oportunidades para el aprendizaje y el desarrollo” (UNICEF, 2020: 1). Estos sistemas suelen estar estructurados en dos componentes: 1) la detección (con las alertas tempranas como herramienta principal) y 2) las intervenciones oportunas de remediación y acompañamiento. Ambos componentes son imprescindibles para reducir la exclusión educativa.

En el paso 1 de la serie, [Exclusión educativa en ALC: ¿cómo los sistemas de protección de trayectorias pueden ayudar?](#), se han introducido de manera sintética las principales nociones relacionadas con los sistemas de protección de trayectorias: conceptualización, objetivos, componentes, evidencia y lecciones aprendidas. En este paso 2, se presentan las distintas aproximaciones para el diseño de sistemas de alerta temprana, que abarcan desde los sistemas simples que identifican alertas mediante la combinación de determinados indicadores hasta los más sofisticados, que utilizan metodologías de aprendizaje automático (*machine learning*). Asimismo, se tratan los aspectos clave para el diseño de un sistema efectivo, y se exponen lineamientos esenciales vinculados al uso de los datos, la definición de indicadores y la potencial aplicación de la inteligencia artificial (IA) en este proceso.



La experiencia internacional ha demostrado que la prevención, intervención y orientación desde niveles tempranos es clave para el diseño y la implementación de sistemas de protección de trayectorias efectivos. Para que los sistemas educativos abandonen su aproximación reactiva y pasen a un enfoque preventivo, los sistemas de alerta temprana se presentan como una herramienta fundamental, que contribuye a detectar estudiantes en riesgo de exclusión. Esto permite una mejor focalización para activar intervenciones oportunas y a tiempo, de acuerdo con las necesidades y demandas de los estudiantes.



2 ¿Qué son los sistemas de alerta temprana?

En el marco de un sistema de protección de trayectorias educativas, los sistemas de alerta temprana constituyen la pieza central para detectar estudiantes en riesgo de exclusión. Cabe recordar que, más que un evento específico, la exclusión educativa es el resultado de un largo proceso de desconexión entre el estudiante y el sistema, por lo que en el camino hacia la exclusión existen claras señales de alerta (Jimerson et al., 2000; Lamb et al., 2010; Román, 2013). Una lectura temprana de estas señales permite detectar el riesgo antes de que suceda la desvinculación (componente de detección), y –por lo tanto– facilita la puesta en marcha de acciones y estrategias de remediación oportunas (componente de intervención), de modo de evitar nuevos procesos de exclusión.

Los sistemas de alerta temprana funcionan, en general, bajo la lógica de “banderas rojas” (UNICEF, 2018). Así, ayudan a las autoridades e instituciones educativas en la identificación de estudiantes en riesgo, a través de patrones de rendimiento y potenciales factores contextuales que puedan resultar en la interrupción de una trayectoria educativa.¹ En otras palabras, sirven para detectar de forma anticipada a aquellos estudiantes que exhiben un comportamiento o desempeño académico que los pone en riesgo de ser excluidos (Frazelle y Nagel, 2015).

Estos sistemas han demostrado ser una herramienta costo-efectiva, por lo que muchos países los han implementado como parte de su estrategia para proteger las trayectorias educativas y disminuir la exclusión escolar (Gutiérrez y Vázquez del Mercado, 2021). Uno de los principales beneficios es que pueden basarse en estructuras ya existentes que funcionan dentro de los ministerios, en los distritos escolares o en las propias escuelas, por lo que no implican grandes cargas de trabajo adicional, a la vez que promueven y facilitan la coordinación.

Existen distintos tipos de sistemas de alerta temprana que pueden implementarse según las condiciones de cada país o sistema educativo: los hay simples, que identifican alertas mediante la combinación de determinados indicadores, hasta sofisticados, que utilizan metodologías de aprendizaje automático.²

1. Definición adoptada por el Departamento de Educación de Estados Unidos, a través de la Encuesta Nacional sobre Estrategias de Escuela Secundaria (HSS, por sus siglas en inglés) Diseñadas para Ayudar a la Graduación de Estudiantes en Riesgo (2017).

2. En la sección 3.3 se presentan ambas aproximaciones.



3 Sistemas de alerta temprana como herramienta de soporte de decisiones en política pública

Los sistemas de alertas tempranas son, en esencia, una herramienta de soporte de decisiones de política pública. Generan información sistematizada con el objetivo de apoyar la toma de decisiones para implementar acciones o intervenciones de política pública, enmarcadas en un sistema de protección de trayectorias educativas.

Actualmente, gracias al desarrollo tecnológico acelerado de las últimas décadas y a la creciente generación y recolección de datos de distintas fuentes de información, estos tipos de sistemas suelen basarse en el uso de metodologías de IA para el procesamiento de datos y/o para la aplicación de reglas de decisión.³ En concordancia con la definición adoptada por la iniciativa fAIr LAC,⁴ los sistemas basados en IA constituyen un amplio espectro de soluciones, desde las que utilizan algoritmos de aprendizaje automático con capacidad de recibir datos y aprender por sí mismos sin decisiones preprogramadas hasta sistemas basados en conocimiento experto y reglas, en los cuales las decisiones y los criterios lógicos son preprogramados por seres humanos (Pombo et al., 2020).

En el caso específico de la protección de trayectorias educativas, los sistemas de toma o soporte de decisiones abarcan desde aquellos basados en indicadores que activan alertas a partir de un cierto umbral definido hasta los que operan con aprendizaje automático y permiten, a través de la predicción y sobre la base de un conjunto de datos del estudiante y de su entorno, detectar a los estudiantes que corren un mayor riesgo de exclusión educativa.

En términos generales, para diseñar e implementar herramientas tecnológicas efectivas para respaldar decisiones de política pública, resulta clave comprender cómo se interrelacionan el ciclo de la política pública con el ciclo de vida de la IA (véase el gráfico 1) (González, Ortiz y Sánchez, 2020). El ciclo de política pública es un marco simplificado que busca representar las fases de desarrollo de

3. La Organización para la Cooperación y el Desarrollo Económicos (OCDE) describe la inteligencia artificial (IA) como “un sistema computacional que puede, para un determinado conjunto de objetivos definidos por humanos, hacer predicciones y recomendaciones o tomar decisiones que influyen en entornos reales o virtuales” (OCDE, 2019), con la idea de que los sistemas de IA están diseñados para operar con distintos niveles de autonomía.

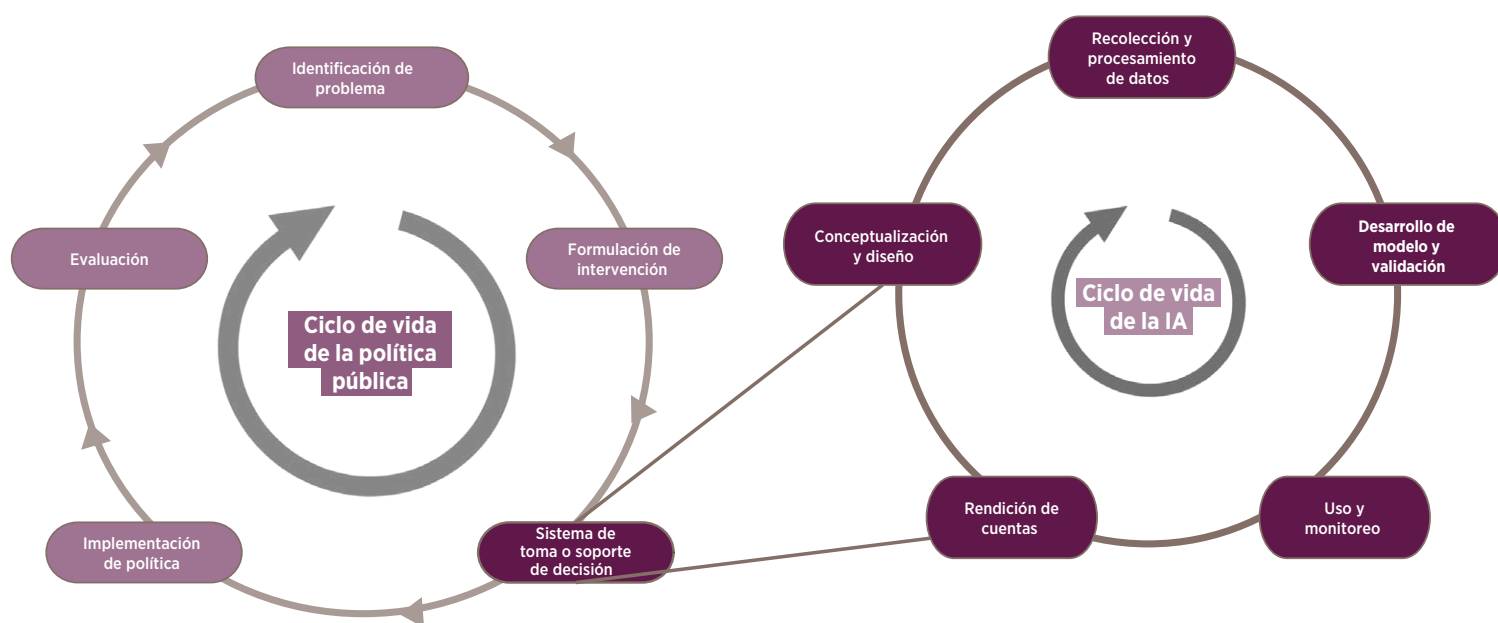
4. fAIr LAC es una alianza entre los sectores público y privado, la sociedad civil y el ámbito académico, que busca incidir tanto en la política pública como en el ecosistema emprendedor para promover el uso responsable y ético de la IA (Pombo et al., 2020). Véase el enlace <https://fairlac.iadb.org/>.



la política: identificación del problema, diseño o formulación de la intervención, implementación y evaluación. El gráfico 1 muestra cómo este ciclo puede ampliarse gracias a la asistencia de sistemas de toma o soporte de decisiones basados en IA como herramientas de política pública.

Cabe enfatizar, por lo tanto, que los sistemas de alerta son una herramienta que permite optimizar la aplicación de la política diseñada, maximizando el impacto de la acción o intervención que se implementará (González, Ortiz y Sánchez, 2020).

GRÁFICO 1 ▪ CICLO DE POLÍTICA PÚBLICA ASISTIDO POR IA



Fuente: Gonzalez, Ortiz y Sánchez (2020).

3.1 Conceptualización y diseño

Tal como se observa en el gráfico 1, el primer paso del ciclo de la política pública consiste en identificar el problema y definir los objetivos. En el caso específico de los sistemas de protección de trayectorias la identificación del problema responde, por ejemplo, al alto porcentaje de estudiantes desvinculados del sistema educativo. Por su parte, el objetivo de política pública describe el estado



ideal que se quiere lograr en términos de la mitigación del problema. Estos objetivos deben ser específicos, medibles, alcanzables, realistas y con temporalidad definida.

Durante la etapa de *conceptualización y diseño*, el encargado de la toma de decisiones de política pública ha de detallar tanto la población objetivo como los grupos y atributos protegidos (género, etnia, religión, discapacidad, nivel de ingresos, etc.) de las intervenciones. Los atributos protegidos deben definirse con conocimiento experto, identificando dónde históricamente se han observado situaciones de inequidad dentro del sistema social o dónde es más probable que surjan. Esta información será fundamental para que, posteriormente, el equipo técnico pueda analizar los datos disponibles y definir su calidad, cobertura y representatividad, así como buscar desigualdades o estados no deseables que afecten a grupos de población en esas interseccionalidades.⁵

En el ciclo de vida de la política pública, una vez identificado el problema y los objetivos por alcanzar, se debe proceder a la formulación de la intervención, es decir especificar las acciones que se implementarán. Las acciones de política desplegadas en el marco de un sistema de protección de trayectorias buscan abordar de manera integral la exclusión escolar. Así se pueden identificar acciones de acompañamiento (encuentros presenciales con familias, espacios de referencia entre pares, programas de tutorías académicas), programas de becas escolares para estudiantes en riesgo de exclusión, programas de modalidades flexibles y adecuación de planes de estudio (véase cuadro 1). Cabe destacar que las posibles intervenciones deben ser definidas y especificadas antes de iniciar el proceso de desarrollo del sistema de alerta temprana, ya que, como se verá más adelante, pueden condicionar de diversas formas cómo debe funcionar el modelo basado en IA.

En el paso 3 de esta serie, se hace foco en las intervenciones oportunas y las estrategias de remediación para la protección de trayectorias.

5. En el caso de sistemas basados en el aprendizaje automático este punto se vuelve aún más relevante, ya que los algoritmos buscan aprender de los patrones que se encuentran en los datos. En consecuencia, estos sesgos históricos pueden transferirse a los modelos, lo cual puede llevar a perpetuar la situación de discriminación. Realizar un análisis de estos subgrupos, tanto en la recolección como durante el entrenamiento ayudará a tomar decisiones acerca de la utilización o no del sistema.



CUADRO 1 ▪ EJEMPLOS DE INTERVENCIONES PARA LA PROTECCIÓN DE TRAYECTORIAS EDUCATIVAS

DIMENSIÓN	PROGRAMA
Acciones de mejora en infraestructura	Rehabilitación de infraestructura
	Construcción de comedores
Acciones de capacitación para docentes	Talleres de capacitación para docentes
Acciones de mejora de programas educativos	Elaboración de planes de educación personalizada
	Modalidades flexibles
Acciones de orientación y acompañamiento	Encuentros presenciales entre maestros, directores y padres de familia
	Acuerdos educativos
	Preparación de una estrategia comunitaria de acompañamiento en vacaciones
	Espacios de estimulación del aprendizaje
	Espacios de referencia entre pares
	Tutorías académicas

Fuente: Elaboración propia sobre la base de CODICEN (2016) y Departamento de Educación de Estados Unidos (2016).

Ahora bien, las características de las intervenciones de política enmarcadas en el sistema de protección de trayectorias pueden condicionar de formas muy diversas el enfoque ideal del sistema de alerta temprana que se desee instituir. Por ello, antes de conceptualizar y diseñar el sistema de toma o soporte de decisiones, es de suma relevancia contar con información detallada sobre el conjunto de intervenciones y estrategias que se implementarán. Entre los principales aspectos de la intervención que inciden en el diseño del sistema de alerta temprana y que, por tanto, deben especificarse, se destacan los siguientes:



Granularidad: Se refiere al nivel al que se aplica la intervención. Por ejemplo, si solo se prevé la implementación de intervenciones de política pública a nivel agregado de escuela o distrito escolar, podría no ser necesario desarrollar un sistema de alerta temprana a nivel del estudiante.⁶

Horizonte de intervención: Concierno a la dimensión temporal en la que se prevé aplicar la intervención de política pública, y que por lo tanto afecta el horizonte temporal del sistema de alerta temprana. A modo de ejemplo, Márquez et al. (2016) describen la puesta en marcha de un sistema de alerta temprana para Guatemala y Honduras, mientras que Muñoz Estuardo (2019) analiza el caso de Uruguay. Los autores se enfocan en la transición entre la escuela primaria y la secundaria, ya que en esas etapas sucede la mayor parte de la deserción escolar reportada. En este caso, el horizonte de aplicación condiciona el desarrollo del sistema, ya que, si las intervenciones se implementan en un período específico, el sistema debe estar diseñado para poder crear alertas previas. En este caso, un sistema de alta precisión, pero que genere alertas luego del período de transición mencionado, no sería de utilidad.

Frecuencia de la intervención: Se refiere a la periodicidad con la que se prevé aplicar la intervención. Se debe definir si la intervención será mensual, semestral o por ciclo escolar, y en función de ello habrán de determinarse los ciclos de actualización del sistema.

Tanto la identificación del problema como la definición de la acción o intervención de política pública que se llevarán adelante constituyen la base para conceptualizar y delinear el sistema de alerta temprana. El diseño de la herramienta dependerá además de otra dimensión clave: la disponibilidad de datos. En este sentido, la selección de información y el acceso a datos relevantes son factores esenciales para los sistemas de alerta temprana. En efecto, es fundamental contar con datos de calidad, precisos, pertinentes y representativos para los grupos protegidos definidos anteriormente.

Asimismo, los sistemas de alerta temprana pueden utilizarse en múltiples niveles del sistema educativo, para dar respuesta a distintos problemas. La existencia de sistemas que generen información individual permite brindar apoyo de forma focalizada a aquellos estudiantes que se encuentren en situaciones de riesgo de exclusión educativa. Cuando esto no sea posible, o los datos no cuenten con la suficiente granularidad y calidad, habrá que desarrollar sistemas para identificar tendencias en el comportamiento agregado de indicadores por áreas territoriales, y orientar programas y recursos hacia las regiones y escuelas de mayor riesgo, lo que permite focalizar la asignación de recursos y utilizarlos donde más se necesiten (Bruce et al., 2011; Josephson y Jayaram, 2018).

6. En caso de que la intervención no se realice a nivel del estudiante, se recomienda minimizar el uso de la información personal que se empleará para generar el sistema de alerta temprana.



Como apoyo para la fase de *conceptualización y diseño* se recomienda consultar el [Manual de formulación de proyectos](#), de la iniciativa fAlr LAC, en particular la ficha de diseño y factibilidad, una herramienta para detectar los principales aspectos clave de un proyecto de IA a fin de evaluar su viabilidad, determinar la pertinencia de la IA como solución y recopilar la información necesaria para el diseño del proyecto (Denis et al., 2021).

3.2 Recolección y manejo de datos

Fuentes de información, manejo y protección de datos

Como ya se ha mencionado, el alcance del sistema de alerta temprana dependerá de la disponibilidad y calidad de los datos, tanto para modelos basados en conocimiento experto o indicadores como para modelos con capacidad predictiva basados en aprendizaje automático. Lo que se precisa es una estrategia de recolección y procesamiento de información que fortalezca la disponibilidad de los datos como insumo para la toma de decisiones y evitar que se produzca una sobrecarga de funciones (principalmente en los centros educativos).

En la práctica, la mayoría de los sistemas de alerta temprana se basan en registros de asistencia, calificaciones e incidentes disciplinarios, incluidas suspensiones o expulsiones (Departamento de Educación de Estados Unidos, 2016). En el fenómeno de la exclusión educativa, las características socioeconómicas del estudiante son factores relevantes (Adelman et al., 2017), pero los signos observables –ausentismo, aislamiento del grupo o rendimiento escolar– suelen ser mejores predictores de la desvinculación que la situación personal o familiar (Mac Iver y Mac Iver, 2009).

Ahora bien, los Sistemas de Información y Gestión Educativa (SIGED) son la base para la construcción de sistemas de alerta temprana efectivos, ya que proveen la información necesaria para su implementación.⁷ Desde una visión integral de los procesos educativos, un SIGED se compone de seis procesos de gestión clave y dos condiciones estructurales (véase el gráfico 2). Los sistemas de alerta temprana constituyen una de las principales herramientas para la gestión estratégica (proceso 6) y se nutren de la información que se genera a partir de la gestión diaria de los distintos niveles del sistema educativo en los otros cinco procesos de gestión clave.

7. Esta fuente de datos contiene buena parte de los factores institucionales e individuales del modelo de Rumberger (2012) presentando en el paso 1 de la serie.



GRÁFICO 2 ■ PROCESOS DE GESTIÓN Y CONDICIONES ESTRUCTURALES DE UN SIGED



Fuente: Arias Ortiz et al. (2021).

Para la implementación de sistemas de alerta temprana, el proceso de gestión de estudiantes y aprendizajes adquiere particular relevancia, ya que genera la información para el seguimiento y monitoreo de la trayectoria escolar. Un SIGED con un alto nivel de madurez cuenta con un registro único de estudiantes en formato digital, lo cual permite efectuar el seguimiento del estudiante a lo largo de toda su trayectoria educativa. Se trata de un repositorio de datos personales, académicos (libreta digital), socioeducativos, de conducta, certificación de estudios, registros de pases, asistencia, exámenes y novedades de promoción, asistencia y repitencia⁸ (Arias Ortiz et al., 2019).

8. Además de permitir la digitalización y automatización de procesos de gestión que posibilitan el seguimiento de las trayectorias escolares, los SIGED facilitan prácticas como la implementación de procesos de matriculación automática, particularmente en el caso de cambios de ciclos, que pueden ayudar a disminuir la exclusión educativa. Tal ha sido la experiencia de Uruguay, que habilitó la matriculación digital en la transición de la escuela primaria a la secundaria, pudo atender en un 90% de los casos las preferencias de las familias y prácticamente eliminó la deserción escolar en esa transición (Arias Ortiz et al., 2019).



A su vez, la disponibilidad de series históricas de los indicadores permite un abordaje más completo de las trayectorias de riesgo y, por lo tanto, mayor precisión en la identificación de los estudiantes en situación potencial de exclusión educativa. La digitalización de los procesos cotidianos de gestión educativa facilita el acceso y la actualización de la información histórica del estudiante (Rivera Pizarro, 2020). Cabe destacar que la interoperabilidad entre sistemas de información es particularmente importante cuando los distintos ciclos educativos atraviesan diversas formas de organización institucional y gobernanza. Por ejemplo, en aquellos casos en que el nivel de gobernanza de las escuelas primarias difiere de los centros educativos de enseñanza media, es vital trabajar en la coordinación e interoperabilidad de los sistemas, a fin de contar con el registro histórico de los estudiantes en sus distintos ciclos educativos.

Asimismo, la información necesaria para implementar sistemas de alerta temprana efectivos será distinta según el tipo de modelo o aproximación utilizado. En los modelos basados en el aprendizaje automático, la disponibilidad de información, tanto referida a trayectorias educativas como a variables sociodemográficas y factores de riesgo no académicos, resulta clave para el entrenamiento de los algoritmos y la precisión de las predicciones. En cambio, los sistemas de alerta basados en conocimiento experto e indicadores no necesariamente requieren el mismo nivel de información y suelen utilizar signos observables asociados al vínculo con el centro educativo. El cuadro 2 muestra un mapeo por dimensiones y detalla las distintas variables que se utilizan para el diseño de sistemas de alerta temprana. Tanto la información a nivel individual como las características del centro educativo al que asiste el estudiante son relevantes y complementarias.



CUADRO 2 ▀ VARIABLES UTILIZADAS PARA SISTEMAS DE ALERTA TEMPRANA QUE PUEDEN SER RECOGIDAS POR LOS SIGED

NIVEL	DIMENSIONES	VARIABLES
CENTRO EDUCATIVO	Infraestructura física y equipamiento	Ubicación georreferenciada del centro educativo al que asiste el estudiante
		Infraestructura y servicios básicos del centro educativo (electricidad, agua, gas, teléfono, internet, etc.)
		Número de estudiantes por aula
	Instituciones educativas	Plan de estudios y currículo
		Evaluaciones a docentes (internas y externas)
	Recursos humanos y financieros presupuestarios	Información de los recursos humanos: títulos, capacitaciones, antecedentes laborales
		Nivel de satisfacción de los docentes
		Relación entre docentes, materias y estudiantes
ESTUDIANTE	Trayectoria educativa y vínculo con el centro	Análisis de la repitencia, extra edad
		Asistencia (inasistencia y motivos) / ausentismo crónico
		Desempeño académico
		Calificaciones y resultados en exámenes estandarizados
		Becas - préstamos - asistencia social
		Actitudes sobre lo académico (disciplina, comportamiento, compromiso, etc.)
	Variables sociodemográficas	Atributos demográficos (género, edad)
		Condición de discapacidad
		Ascendencia étnico-racial
		Lugar de residencia, condición migratoria
		Alimentación y salud
		Composición familiar
		Violencia intrafamiliar
		Educación especial
		Condición económica del hogar
		Violencia escolar, acoso (<i>bullying</i>)
	Factores de riesgo no académicos	Paternidad o maternidad adolescente, otras responsabilidades de cuidados familiares
		Consumo problemático de alcohol y/o sustancias

Fuente: Elaboración propia.

Nota: En cuanto a los atributos demográficos, variables como sexo, edad y discapacidad no son factores que condicionen o incrementen la probabilidad de desvinculación educativa, pero aun así es importante poder contar con estos atributos durante el desarrollo del sistema, ya que ayudan a realizar los análisis de sesgo e inequidad de los resultados.



En la región existe una gran diversidad en los niveles de madurez de los SIGED. Por ejemplo, no todos los países cuentan con un registro nominal de los estudiantes que permita la identificación única de cada uno y su trayectoria, así como la asociación entre estudiantes y centros. Además, se observan serios problemas de interoperabilidad y fragmentación entre los distintos subsistemas utilizados para el registro, lo que genera bases de datos que no se comunican entre sí, tanto por diferencias conceptuales como tecnológicas. Esto trae aparejadas pérdidas de oportunidades y costosas ineficiencias (Arias Ortiz et al., 2021). En la publicación [Los Sistemas de Información y Gestión Educativa \(SIGED\) de América Latina y el Caribe: la ruta hacia la transformación digital de la gestión educativa](#), se presentan los resultados de un estudio diagnóstico realizado en 16 sistemas educativos públicos de ALC y se proponen recomendaciones de políticas para avanzar hacia una gestión educativa más eficiente (Arias Ortiz et al., 2021).

La falta de disponibilidad de datos en ALC hace que no siempre sea posible generar sistemas de alerta temprana que permitan el análisis a nivel del estudiante. Esto puede suceder por distintas razones, ya sea porque los datos del período escolar toman tiempo en concentrarse en una sola base o porque no existen los registros digitalizados a ese nivel de desagregación. En esos casos, una alternativa es desarrollar sistemas a nivel de centro educativo. Como se observa en el cuadro 2, algunas variables de las dimensiones al interior de los establecimientos escolares pueden emplearse para alimentar los sistemas, en este caso agregadas a nivel de centro. Un modelo sencillo que permita identificar escuelas a las que concurren estudiantes en situación de alto riesgo ayudará a las autoridades a planificar políticas agregadas que no estarían disponibles de otra manera.

En los últimos años, y en particular en 2020 como resultado de la pandemia de COVID-19, los sistemas educativos han incrementado el uso de herramientas digitales para el aprendizaje a través de nuevas plataformas. Esta digitalización del entorno de aprendizaje ha aumentado la disponibilidad de nueva información, en algunos casos ya integrada en los SIGED, que también puede incorporarse en los sistemas de alerta y facilitar la aplicación de modelos analíticos y de aprendizaje automático para investigación y evaluación del aprendizaje (Cohen, 2017).

Algunos sistemas de alerta temprana también utilizan como complemento información proveniente de encuestas y cuestionarios (Sansone, 2019). Para este tipo de datos vale destacar el empleo de indicadores referidos al número de horas de estudio diarias, al estudio en grupo, a los hábitos de estudio, al nivel de motivación, a los recursos para estudiar, a la cantidad de hermanos o hermanas, a la posición como hijo o hija mayor, del medio o más joven, al estímulo de los padres para el estudio, a la distancia a la escuela, al interés en las materias y al nivel de dificultad de estas (Márquez et al., 2016).

Por otra parte, también se recomienda la utilización de datos de otros programas y organismos gubernamentales, puesto que varios indicadores educativos y sociales se recopilan por medio de



las actividades regulares de distintos ministerios. Se destaca la relevancia de la participación en programas sociales, en particular el acceso a transferencias no contributivas, así como datos de salud, hacienda y seguridad social, entre otros. La coordinación y el trabajo conjunto con otras áreas del Estado resulta clave para no duplicar esfuerzos y aumentar la eficiencia (Rivero Pizarro, 2020). En este sentido, el uso de documentos de identidad provistos por los registros de personas facilita el intercambio de información con cualquier otro programa u organismo que registre esos datos sobre sus beneficiarios (Arias Ortiz et al., 2019).

Uno de los principales retos en términos del manejo de datos se refiere a la gobernanza y protección de datos personales. Algunas iniciativas han utilizado información de los estudiantes fuera de la escuela, como perfiles temáticos de interés por alumno, integración y conexiones en redes sociales (Berens et al., 2018). Esta información puede ser muy útil, pero hay que asegurarse de contar con las facultades legales y el consentimiento necesario para el uso de los datos; garantizar el derecho a la privacidad de los estudiantes, minimizar la información personal que se empleará para generar el sistema de alerta, y confirmar la presencia de estructuras y mecanismos concretos de gobernanza y seguridad.⁹ La pandemia provocó una transición acelerada hacia la educación digital, lo cual dejó en evidencia el desconocimiento de los recursos humanos con respecto a las prácticas que deben ponerse en marcha para no comprometer la seguridad de los datos de sus estudiantes. Según una encuesta realizada por el Banco Interamericano de Desarrollo (BID) y el Laboratorio de Resiliencia Eón de C Minds, aplicada en siete países de la región,¹⁰ el 72,3% de los docentes no cuenta con capacitación (o esta es insuficiente) para temas de privacidad de datos y uso responsable de plataformas y herramientas digitales (Del Pozo, del Campo Alcocer y Róo Rubí, de próxima publicación).

Sesgos, estados indeseables e información incompleta acerca de la población

Una vez identificados los datos disponibles y validadas las consideraciones éticas, legales y de gobernanza para su uso, se debe continuar con un análisis exploratorio que indique la calidad, relevancia y cobertura de los datos disponibles. Para efectuar dicho análisis, se toma en cuenta toda la información provista durante la etapa de *conceptualización y diseño*, ya que el desarrollo y el ciclo de vida de la IA se ven afectados tanto por la comprensión del problema como por los objetivos, la población y los atributos protegidos definidos durante el ciclo de política pública.

9. Se recomienda completar el perfil de datos (González, Ortiz y Sánchez, 2020)

10. Brasil, Colombia, Costa Rica, México, Perú, Panamá y Uruguay.



Ya que todo entorno social presentará inequidades, es importante que exista una comunicación permanente entre el responsable de las políticas públicas y el equipo técnico encargado del desarrollo del sistema de alerta. En esta fase, se debe implementar un análisis exploratorio con base en el registro histórico de estudiantes, con el objetivo de realizar cruces y conteos sobre las variables de interés separadas por los grupos y atributos protegidos (definidos durante la etapa de *conceptualización y diseño*). El análisis permitirá apreciar si se cuenta con la cobertura suficiente para garantizar la representatividad de los subgrupos de población de interés o si existe una sobre o subrepresentación de algún grupo en particular que pueda llegar a tener un impacto en los resultados del modelo. A modo de ejemplo, el cuadro 3 presenta un conteo de observaciones del registro histórico de estudiantes aprobados y no aprobados en escuelas urbanas y rurales de Uruguay (ANEP, 2021). Como es evidente, en los resultados aparece una mayor cantidad de observaciones asociadas a zonas urbanas, y la proporción de aprobados y no aprobados difiere según área geográfica. Además, se constata la falta de información para el segundo grado en zonas rurales. Estas diferencias y la ausencia de ciertos valores se pueden deber a múltiples razones, desde falta de conectividad en los sistemas en zonas rurales hasta dificultades para la recolección de datos, y diversidad de enfoques y programas educativos. Las diferencias constatadas deben tomarse en cuenta para no generalizar un modelo que en el largo plazo pueda perjudicar a poblaciones minoritarias –en este caso, estudiantes de zonas rurales– de la población objetivo.

CUADRO 3 ▪ EJEMPLO DE AGRUPADO DE VARIABLE DE INTERÉS SEPARADO POR GRUPO PROTEGIDO. CANTIDAD DE ESTUDIANTES DE SECUNDARIA EN ZONAS URBANA Y RURAL, URUGUAY

PLAN	GRADO	ZONA URBANA			ZONA RURAL		
		Aprobados	Reprobados	TOTAL	Aprobados	Reprobados	TOTAL
CES	1	88.987	47.425	136.712	5.364	1.460	6.824
	2	91.090	11.242	102.332	0	0	0

Fuente: Documentos de consultoría realizada por ANEP (2021).

Aunque el sesgo y la falta de representatividad afectan a todo tipo de sistemas de soporte de decisiones, resulta particularmente relevante para los sistemas basados en el aprendizaje automático, ya que los algoritmos aprenden patrones de la información histórica. Por lo tanto, si la base de datos sobre la que se entrena el algoritmo no cuenta con información de un grupo o atributo protegido



o presenta sesgos históricos, se corre el riesgo de que el sistema aprenda y replique esos patrones. A modo de ejemplo, si se realizara una encuesta sobre el interés de los alumnos en diversas asignaturas, se podrían encontrar sesgos ocasionados por estructuras de inequidad social que no se desea perpetuar. Es el caso de la brecha de género en el sector de Ciencia, Tecnología, Ingeniería y Matemáticas (CTIM), que poco a poco se ha ido acortando, aunque persiste un porcentaje mayor de hombres que de mujeres en la cursada de esas asignaturas (FEM, 2016). El equipo técnico debe tener muy claro sobre qué atributos y poblaciones debe realizar análisis comparados de forma que pueda controlar su cobertura y los posibles sesgos históricos que estén presentes en la recolección de datos para alinearse con los objetivos de política pública.

3.3 Desarrollo del modelo y validación

Modelos de alerta temprana basados en conocimiento experto o indicadores

Las primeras iniciativas para crear sistemas de alerta temprana se enfocaron en modelos basados en conocimiento experto e indicadores, que consisten en generar indicadores simples de riesgo –por ejemplo, bajas calificaciones y baja asistencia escolar–, definir umbrales estáticos de anomalías y establecer reglas para su agregación (Bowers et al., 2013). Este tipo de modelos, acompañados de una buena implementación, han demostrado ser efectivos para detectar estudiantes en situación potencial de exclusión.

Tal como su nombre lo indica, este tipo de modelos se basa en el conocimiento experto, es decir en los saberes acumulados, con base en la evidencia, acerca de los principales factores de riesgo asociados a la exclusión educativa. La selección de indicadores es crucial para poder identificar de manera precisa aquellos estudiantes que efectivamente se encuentran en situación potencial de exclusión (Bruce et al., 2011). Esta selección debe tomar como base los resultados de investigaciones que asocian el fenómeno de la exclusión a factores concretos, pero también debe considerar las características de la exclusión educativa en el contexto particular, lo que permite generar indicadores de alerta temprana más precisos (Balfanz, 2008). En este sentido, si bien existen ciertos indicadores que pueden considerarse como “básicos” y deberían estar presentes en cualquier sistema de alerta temprana, la relevancia de otros puede estar determinada por las características de la población del país y/o del sistema educativo. Una de las estrategias más utilizadas para la selección de indicadores es analizar los registros históricos, es decir, la información disponible sobre estudiantes en situación de exclusión educativa de años anteriores, lo que permite seleccionar indicadores sobresalientes para detectar las situaciones de riesgo en las generaciones futuras, antes de que se produzca la desvinculación (UNICEF, 2018).



El modelo de asistencia, comportamiento y desempeño escolar (ABC, por sus siglas en inglés, correspondientes a *attendance, behavior and course performance*) resume los tres componentes básicos que la literatura ha identificado como los predictores más poderosos en términos de exclusión educativa (Bruce et al., 2011). Dicho modelo se basa en el análisis de la asistencia, el comportamiento y las calificaciones como indicadores centrales de riesgo educativo. Ha sido implementado por el National High School Center Early Warning System, que propone umbrales de corte de referencia para cada una de las tres dimensiones consideradas: asistencia del estudiante (inasistencias del 10% o más), rendimiento del curso (uno o más cursos reprobados y promedio de calificaciones menor o igual a 2 en una escala de 4 puntos), y comportamiento (remisiones, suspensión dentro o fuera de la escuela, o calificaciones de comportamiento cuyos umbrales deben definirse en el ámbito local) (Frazelle y Nagel, 2015). El reporte de cualquiera de estas variables fuera del rango esperado genera una alerta.

Por su parte, la Universidad John Hopkins también ofrece sugerencias en la definición de umbrales para detectar a los estudiantes en riesgo de exclusión. Para ello, recurre a tres niveles de categorización: “fuera de camino” (*off track*), “en camino resbaloso” (*sliding*) o “camino a la graduación” (*on track to graduation*) (véase el cuadro 4) (Frazelle y Nagel, 2015). En consonancia con lo mencionado en secciones anteriores, cabe considerar también la dimensión temporal, ya que, si se espera que el sistema pueda generar alertas a lo largo del ciclo escolar, es necesario establecer parámetros de medición y umbrales para distintos períodos. Más allá de los umbrales de referencia, se recomienda que los equipos puedan analizar y evaluar los puntos de corte sobre la base de los datos históricos, para garantizar que los umbrales tengan sentido en el contexto concreto de su sistema educativo

CUADRO 4 ■ SISTEMA DE INDICADORES Y UMBRALES DE ALERTA TEMPRANA SUGERIDO POR LA UNIVERSIDAD JOHN HOPKINS

Umbrales de corte	Asistencia (cantidad de inasistencias)		Comportamiento				Rendimiento académico	
			Derivaciones a dirección		Suspensiones			
	Trimestre	Año escolar	Trimestre	Año escolar	Trimestre	Año escolar	Matemáticas y Lectura ^a	Cursos básicos ^b
Fuera de camino	9 días	36 días	2	6	1	2	Libreta de calificaciones con F	Libreta de calificaciones con F
En camino resbaloso	5-8 días	19-35 días	1	3-5	0	0-1	Libreta de calificaciones con D	Libreta de calificaciones con D
Camino a la graduación	4 días o menos	18 días	0	0-2	0	0-1	Libreta de calificaciones con A, B o C	Libreta de calificaciones con A, B o C

a: Secundaria baja

b: Secundaria alta

Fuente: Universidad John Hopkins (2012: 10).



Según un relevamiento realizado por el National High School Center Early Warning System, en 2015 el 52% de las escuelas de Estados Unidos contaba con sistemas de alerta temprana basados en conocimiento experto. Los sistemas de alerta temprana de la mayoría de estas escuelas se fundamentan en datos referidos a la asistencia de los estudiantes (92%), las calificaciones de los cursos (91%), el ausentismo escolar y/o el ausentismo crónico (82%), así como incidentes disciplinarios, incluidas suspensiones o expulsiones (79%), en concordancia con los predictores básicos del modelo ABC. El mismo relevamiento señala que algunas escuelas también incorporan otros datos complementarios y que son aquellas con menor tasa de graduación y mayor tasa de pobreza las que tienden a incluir mayor cantidad de datos adicionales al modelo ABC. Como principales indicadores complementarios utilizados se destacan la participación en el sistema de justicia penal, la falta de vivienda, embarazo/paternidad o maternidad adolescente, extra-edad, entre otros. El National High School Center Early Warning System resalta este hallazgo como positivo y considera que, si bien los predictores ABC constituyen una pieza central de casi todos los sistemas de alerta temprana, las escuelas también han ejercido discreción en la recopilación de datos adicionales adaptados a sus contextos y poblaciones (Departamento de Educación de Estados Unidos, 2016). Cuando los sistemas de alerta temprana se desarrollan a nivel nacional o regional, resulta clave que tengan en cuenta las dimensiones regionales y locales relevantes para el fenómeno de la exclusión educativa. En otras palabras, el diseño de sistemas de alerta temprana desde el nivel central debe asegurar la inclusión de indicadores locales, de manera de desarrollar sistemas más eficientes y sensibles a la identificación de estudiantes en riesgo.

Además de la asistencia, el comportamiento y las calificaciones, en ALC en particular sobresalen como indicadores visibles el embarazo adolescente y la extra-edad (Adelman y Székely, 2017). La extra-edad, ya sea por el inicio tardío de la escolaridad, o por efecto de la repetición, es uno de los principales predictores de exclusión educativa en la región (Manacorda; 2006; Adelman y Székely, 2017). Cabe destacar que la importancia relativa de los diferentes indicadores cambia a lo largo del ciclo de vida; por ejemplo, durante la adolescencia, los indicadores asociados al grado de violencia o delincuencia de la comunidad suelen revestir mayor relevancia (Adelman y Székely, 2017).

La cantidad de indicadores seleccionados es un factor clave para los sistemas de alerta temprana basados en conocimiento experto. Al contrario de lo que sucede con los sistemas basados en el aprendizaje automático, en este caso “más” no siempre quiere decir “mejor”. Los expertos advierten que seleccionar demasiados indicadores puede crear una cantidad abrumadora de datos para analizar e interpretar en este tipo de sistemas, lo cual no es recomendable (University of Chicago Consortium on Chicago School Research, 2014). En este sentido, una buena estrategia es establecer primero un conjunto básico de indicadores, por ejemplo, el modelo ABC, y luego incorporar otros indicadores complementarios, evaluando si estos aumentan sustancialmente el número de estudiantes identificados como en riesgo de exclusión (Frazelle y Nagel, 2015). La sensibilidad de los indicadores seleccionados es otro de los factores para tener en cuenta. Se debe evitar caer en sistemas que, lejos de focalizar la acción, determinen una proporción demasiado grande de estudiantes



en riesgo y que, por lo tanto, no permitan la detección oportuna de quienes se encuentren en una situación potencial de exclusión (UNICEF, 2018). Para evitar esto, se recomienda como estrategia la combinación de indicadores, así como su ponderación.

En la región, países como Colombia, Brasil y Uruguay, entre otros, han desarrollado sistemas de alerta temprana basados en conocimiento experto o indicadores. Estos países han seleccionado un conjunto de indicadores y reglas para detectar estudiantes en riesgo de exclusión. Por ejemplo, en Colombia se utiliza el tablero escolar Índice de Riesgo de la Trayectoria Escolar Educativa (IRTE), con 16 indicadores organizados en cuatro subíndices: cargas familiares del estudiante, clima escolar, contexto socioeconómico y trayectoria educativa pasada. Por su parte, en el marco del Sistema de Protección de Trayectorias Educativas (SPTE), Uruguay ha puesto en marcha el módulo de asistencia, que consiste en un sistema de alerta temprana de inasistencias reiteradas para uso de los centros escolares, en particular los equipos de seguimiento y acompañamiento de las trayectorias educativas (Muñoz Stuardo, 2020). Se utilizó en forma piloto en 2018 y se lanzó de manera universal en el sistema educativo uruguayo en mayo de 2019 (Muñoz Stuardo, 2020). De manera similar, el Programa de Combate ao Abandono Escolar implementado en el Estado de Paraná (Brasil) a partir de 2013, también se basa en un único indicador de asistencia escolar. Cuando un estudiante ha tenido cinco inasistencias consecutivas, o siete inasistencias alternadas, el sistema activa una notificación a la Red de Protección Social de Niños y Adolescentes –compuesta por escuelas, centros de asistencia social, consejos comunitarios y otros actores– para ejecutar acciones y estrategias acordes a cada situación. El paso 4 de esta serie recopila diversas experiencias de sistemas de alerta temprana implementadas en la región, con diferentes grados de automatización y uso de datos.

Sistemas de alerta temprana basados en el aprendizaje automático

En los últimos años, con el aumento de la disponibilidad de datos y metodologías analíticas de procesamiento, los modelos de alerta temprana basados en conocimiento experto han comenzado a ser sustituidos por algoritmos de aprendizaje automático, principalmente con dos tipos de enfoques: i) enfoques no supervisados para la aplicación de intervenciones grupales mediante algoritmos de agrupamiento o clusterización y ii) enfoques supervisados para la predicción de variables de interés (por ejemplo, desvinculación educativa) a partir de una diversidad de algoritmos, que abarcan desde bosques aleatorios (Aguiar et al., 2015) hasta redes neuronales (Sattar et al., 2016).

Los algoritmos de aprendizaje supervisado son modelos entrenados con bases de datos históricos del comportamiento de estudiantes de generaciones anteriores que ya han pasado por el ciclo educativo y cuya trayectoria, por lo tanto, se conoce. Estos modelos se pueden enfocar en predecir distintas características o factores de riesgo, es decir, variables objetivo o de interés. Los algoritmos aprenden de la relación entre características descriptivas (o predictores) y la variable objetivo



dentro de un conjunto de datos, a partir de lo cual pueden predecir con precisión el resultado de las observaciones futuras o bien permiten comprender mejor la relación entre la variable de interés y los predictores (Chung y Lee, 2019).

Tal como se ha descrito en la sección de *conceptualización y diseño*, la variable de interés debe definirse en función del tipo de acción o intervención de política pública que se quiera llevar a cabo. En la literatura, para el abordaje de la exclusión educativa, la principal variable objetivo es la variable de “desvinculación escolar”, que se construye como una variable dicotómica que identifica con 1 a aquellos estudiantes que hayan tenido al menos un episodio de desvinculación a lo largo de su trayectoria y con 0 en caso contrario (Sansone, 2019). Sobre la base de esta variable de interés, los modelos predicen la probabilidad de desvinculación para los nuevos estudiantes, con un horizonte de tiempo determinado. Sin embargo, los sistemas de alerta temprana también pueden ser entrenados para identificar otros riesgos educativos, como el riesgo de no graduarse a tiempo (Aguiar et al., 2015), el desempeño académico y las inasistencias, entre otros. Por ejemplo, en contextos digitales, especialmente para modelos aplicados en cursos en línea o cursos masivos abiertos en línea (MOOC, por sus siglas en inglés), la definición de la variable de interés puede contemplar la frecuencia de las visitas y la duración de las sesiones en la plataforma (Prenkaj et al., 2020).

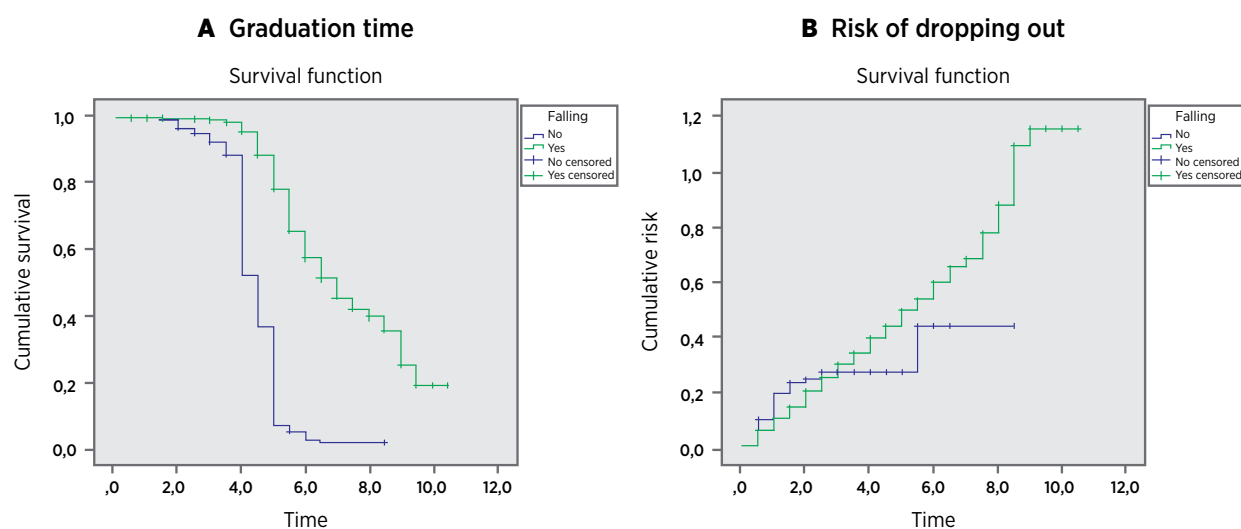
Por su parte, los algoritmos de aprendizaje no supervisado, a diferencia del supervisado, no tienen como objetivo predecir un resultado durante el entrenamiento, sino que buscan en la información patrones estructurales que le permitan crear asociaciones entre las observaciones para descubrir grupos o individuos similares dentro de la información de entrenamiento (*clustering*) (Pombo et al., 2020). En efecto, los algoritmos de clusterización, como k-means y el *clustering* jerárquico, se han utilizado para crear perfiles de desempeño escolar para alumnos con características semejantes (Iam-On y Boongoen, 2017). Esto permite idear grupos o perfiles de estudiantes para implementar intervenciones grupales, lo que puede reducir el costo de las intervenciones o estrategias que se implementarán.

Cabe destacar que un sistema de alerta temprana no necesariamente debe basarse en un único modelo, sino que puede diseñarse como un conjunto de modelos que incluya tanto algoritmos supervisados como no supervisados. Por ejemplo, Sansone (2019) utiliza un modelo supervisado para identificar estudiantes con riesgo de exclusión educativa, y posteriormente emplea algoritmos no supervisados para reunir en grupos a los estudiantes en riesgo identificados, en base a sus características observables. Con esta diferenciación también es posible evaluar cómo una política tiene diferentes impactos entre los estudiantes de varios grupos. Por su parte, Aguiar et al. (2015) combinan dos tipos de algoritmos supervisados. En primer lugar, realizan una estimación binaria de probabilidad de desvinculación, y posteriormente utilizan un método de análisis de supervivencia, mediante una regresión tipo Cox, para crear un indicador de “urgencia”. Las metodologías de análisis de supervivencia son algoritmos supervisados que se enfocan en predecir el tiempo esperado hasta que suceda un evento de interés, en este caso la desvinculación educativa. Con este tipo de



sistemas se puede modelar la trayectoria de un estudiante, crear un indicador de riesgo de desvinculación dinámico en el tiempo e identificar cuándo el riesgo es mayor (gráfico 3). Esto permite priorizar las acciones o intervenciones para estudiantes que requieran una atención más inmediata. Es decir, si dos alumnos fueron clasificados con un riesgo alto de desvinculación escolar, se puede priorizar la intervención para aquellos estudiantes que el modelo prediga que desertarán antes.

GRÁFICO 3 ■ MODELO DE SUPERVIVENCIA APLICADO A LA DESVINCULACIÓN EDUCATIVA



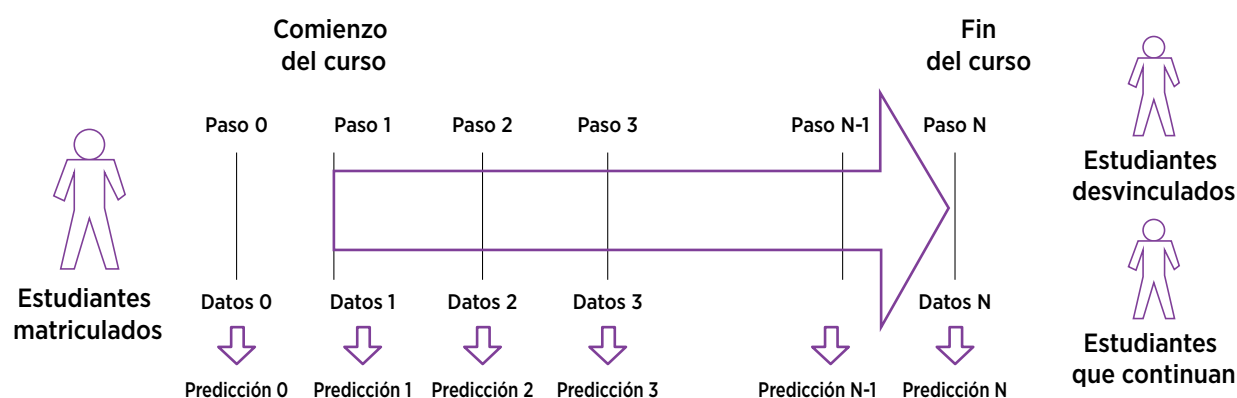
Fuente: Costa et al. (2018).

Ahora bien, como ya se mencionó, el horizonte de predicción y la periodicidad del entrenamiento se deben ajustar al diseño y a la temporalidad de la intervención. Parece lógico que cuanto antes se pueda hacer una predicción que sea confiable, mayor tiempo tendrán los equipos educativos para aplicar las estrategias e intervenciones de política pública que lleven a reducir el riesgo de exclusión. Sin embargo, a mayor anticipación, menor será la cantidad información disponible sobre la trayectoria educativa del estudiante, y es probable que el sistema tenga mayor margen de error (Márquez et al., 2016). En efecto, una de las claves para implementar este tipo de sistemas consiste en alcanzar un equilibrio entre la posibilidad de contar con alertas lo suficientemente anticipadas como para poder intervenir y dar el tiempo necesario para que haya información suficiente para realizar una predicción de calidad.



Cabe destacar que también es posible diseñar sistemas que incluyan más de un modelo durante la trayectoria educativa, actualizando el riesgo identificado por alumno conforme haya más información disponible y ajustando las intervenciones en consecuencia. La definición de los cortes y horizontes de intervención dependerán principalmente de la disponibilidad de datos, así como de la capacidad de las instituciones para ajustar las acciones de política pública.

GRÁFICO 4 ■ HORIZONTES DE INTERVENCIÓN



Fuente: Márquez et al. (2016).


Datos no balanceados

Uno de los principales problemas al entrenar un sistema de alerta temprana basado en el aprendizaje automático es el desequilibrio inherente en la base de datos de entrenamiento entre quienes se desvinculan del sistema educativo y quienes no lo hacen. En otras palabras, la cantidad de información histórica de estudiantes que se han desvinculado del sistema educativo suele ser mucho menor que la de aquellos que no, por el simple hecho de que los primeros son menos. Para los sistemas de aprendizaje automático supervisado, la clase minoritaria (es decir, aquella en la que hay menos cantidad de casos) se vuelve difícil de aprender, lo que podría dificultar la construcción del modelo predictivo. Para mitigar este tipo de fenómenos, se pueden utilizar técnicas de sub y sobre muestreo como SMOTE (por sus siglas en inglés, *Synthetic Minority Over-Sampling Technique*), que ayuda a equilibrar las clases mediante un aumento de la importancia relativa del grupo minoritario al realizar el entrenamiento del modelo. A modo de ejemplo, el gráfico 5 presenta un conteo



de observaciones del registro histórico de estudiantes aprobados y no aprobados en escuelas de Uruguay (ANEP, 2021) (véase el gráfico 5).¹¹

GRÁFICO 5 ■ DISTRIBUCIÓN DE LOS ESTUDIANTES DEL PRIMER AÑO DE SECUNDARIA SEGÚN APROBACIÓN, PROYECTO ANEP



Fuente: Documentos de consultoría realizada por ANEP (2021).

Evaluación y validación de modelos

Un punto fundamental para tomar en cuenta en modelos supervisados entrenados con bases de datos no balanceadas es que el análisis de su error puede ser engañoso.¹² Esto se debe a que métricas como la exactitud –que determina la proporción de las observaciones que el modelo predijo correctamente– analizan el desempeño de la clasificación para ambas categorías, es decir exclusión y no exclusión, lo que puede llevar a una mala interpretación y a una falsa confianza del desempeño del sistema. A modo de ejemplo, si en un sistema educativo la tasa de exclusión educativa es del 5% --y, por lo tanto, la de continuidad es del 95%–, entonces un modelo entrenado que prediga un

11. Toda técnica de sobre o sub muestreo debe aplicarse de forma posterior a la partición de la base de datos en entrenamiento y evaluación, ya que hacerlo antes puede generar fuga de información de la tabla de entrenamiento a la de validación (González, Ortiz y Sánchez, 2020).

12. El *Manual de ciencia de datos* de fAIr LAC describe, para cada una de las fases de desarrollo de un modelo de aprendizaje automático, los principales errores y riesgos técnicos que se deben tomar en cuenta, así como medidas para mitigarlos (González, Ortiz y Sánchez, 2020)



100% de continuidad educativa y un 0% de exclusión tendría una exactitud del 95%. En este caso extremo la métrica de exactitud puede llevar a una falsa confianza en su desempeño, ya que, si bien su exactitud es del 95%, su utilidad para predecir estudiantes en riesgo de exclusión es nula. Por ello, siempre hay que descomponer el error entre falsos positivos (identificar erróneamente a un estudiante como en riesgo de desvinculación escolar cuando no lo esté) y falsos negativos (identificar erróneamente a un estudiante como fuera de riesgo cuando sí lo está), y analizar de forma conjunta métricas como precisión, sensibilidad y especificidad (véase el cuadro 5). Cabe aclarar que la etapa de evaluación y validación de modelos supervisados se realiza sobre la base de datos históricos de estudiantes que ya han transitado el ciclo educativo, lo que permite obtener las métricas mencionadas.

CUADRO 5 ■ **MATRIZ DE CONFUSIÓN DE CLASIFICACIÓN**

		REAL	
		POSITIVO	NEGATIVO
PRECISIÓN	POSITIVO	Verdadero Positivo (VP)	Falso Positivo (FP)
	NEGATIVO	Falso Negativo (FN)	Verdadero Negativo (VN)
Exactitud = $\frac{VP + VN}{VP + VN + FP + FN}$		Precisión = $\frac{VP}{VP + FP}$	Sensibilidad = $\frac{VP}{VP + FN}$

Fuente: González, Ortiz y Sánchez (2020).

La elección de una métrica de error para seleccionar los puntos de corte de probabilidad de clasificación, así como la elección entre distintos modelos, lleva consigo una decisión de política pública que debe ser considerada como tal. En algunos contextos, por su espacio de aplicación, el responsable de las políticas públicas puede querer minimizar los falsos positivos, mientras que



para otros escenarios podría ser más importante minimizar los falsos negativos. Esta decisión es un *tradeoff* entre ambos objetivos, ya que no siempre se puede optimizar una sin sacrificar la otra. Por ejemplo, si el centro escolar o el sistema educativo desean cubrir la mayor cantidad posible de estudiantes en riesgo de exclusión, buscarán el modelo que demuestre mayor sensibilidad (minimizando falsos negativos), a costa de tener estudiantes que el modelo haya clasificado incorrectamente con una alta probabilidad de desvinculación escolar, lo cual aumenta el costo de la intervención. En cambio, si el centro o el sistema cuentan con pocos recursos, es posible que establezcan como objetivo maximizar la precisión (minimizando falsos positivos), con lo cual se reduce el número de estudiantes clasificados como en riesgo y que en realidad no lo están, pero a su vez se eleva el peligro de clasificar como fuera de riesgo a estudiantes que efectivamente se encuentran en riesgo de exclusión educativa.¹³

Como ya se describió para las etapas anteriores, la información incompleta, la falta de representatividad y los supuestos sobre su recolección, así como los errores en el desarrollo del modelo, pueden ocasionar resultados sesgados que lleven a tomar decisiones indeseables, injustas o discriminatorias para distintos subgrupos (González, Ortiz y Sánchez, 2020). Por ello, no solo es menester evaluar las métricas de error elegidas para la población en general, sino aplicar las mismas métricas de error diferenciadas por grupos y poblaciones protegidas.¹⁴ El gráfico 6 presenta un ejemplo de un análisis por grupos de la matriz de confusión, que señala en porcentajes la composición de falsos positivos y falsos negativos de los resultados del modelo desagregado por sexo. Como puede apreciarse, en este caso ambos grupos analizados presentan porcentajes muy similares de falsos positivos y falsos negativos, lo que da cuenta de que no se constatan diferencias en la métrica de error según sexo. Este tipo de análisis se debe hacer sobre todas las interseccionalidades definidas por el formulador de políticas públicas durante la etapa de *conceptualización y diseño*.

13. En general, para este tipo de sistemas se recomienda el uso de la curva de precisión-sensibilidad (*precision recall curve*), a fin de evaluar clasificadores entrenados con bases de datos desbalanceadas. Para obtener más información sobre las particularidades de las métricas de error y los riesgos de su evaluación fuera de contexto, véase González, Ortiz y Sánchez (2020).

14. Se recomienda completar el perfil del modelo (González, Ortiz y Sánchez, 2020).



GRÁFICO 6 ■ ANÁLISIS DE SESGO DE SEXO, PROGRAMA PILOTO DE ANEP

VARONES				
		FALSOS POSITIVOS (%)	FALSOS NEGATIVOS (%)	PRECISIÓN (%)
		13,8	1,7	84,4
Matriz de confusión				
REAL	PREDICCIÓN			TOTAL
		POSITIVO	NEGATIVO	
	POSITIVO	84.1% (243)	1.7% (5)	85.8% (248)
	NEGATIVO	13.8% (40)	0.3% (1)	14.2% (41)
TOTAL		97.9% (283)	2.1% (6)	

MUJERES				
		FALSOS POSITIVOS (%)	FALSOS NEGATIVOS (%)	PRECISIÓN (%)
		13,7	1,4	84,8
Matriz de confusión				
REAL	PREDICCIÓN			TOTAL
		POSITIVO	NEGATIVO	
	POSITIVO	84.4% (178)	1.4% (3)	85.8% (181)
	NEGATIVO	13.7% (29)	0.5% (1)	14.2% (30)
TOTAL		98.1% (207)	1.9% (4)	

Fuente: Documentos de consultoría realizada por ANEP (2021).

Existen otros riesgos que se deben tomar en cuenta durante el desarrollo de un sistema basado en aprendizaje automático, como los relacionados con errores de validación, fugas de información o degradación del desempeño, entre muchos otros¹⁵.

15. Se recomienda que el equipo técnico utilice la publicación Uso responsable de IA para política pública: manual de ciencia de datos (González, Ortiz y Sánchez, 2020).



3.4 Uso y monitoreo

Una vez desarrollado, validado y elegido el modelo más adecuado, comienza la etapa de implementación, en la cual el sistema de IA provee resultados para la toma de decisiones. En este caso en particular, arroja las alertas tempranas sobre los estudiantes con mayor riesgo de exclusión escolar. En esta fase resulta clave identificar dos momentos: el uso de los resultados que activará la intervención de política pública y el monitoreo del desempeño del modelo, que garantiza que las alertas tempranas continúen siendo relevantes a lo largo del tiempo y, por ende, las intervenciones generadas también.

Apropiación del modelo

Parte fundamental para el funcionamiento efectivo de los sistemas de alerta temprana radica en presentar las herramientas desarrolladas a docentes, directores y autoridades, a fin de garantizar una interacción correcta con los resultados del sistema cuando un estudiante está en riesgo de exclusión. Por lo tanto, se deben utilizar herramientas de visualización efectivas y amigables, para que los usuarios finales puedan apropiarse del sistema (Frazelle y Nagel, 2015). El desafío en este punto radica en cómo hacer de esta información un insumo relevante para el diario accionar de docentes, directores, y niveles de conducción, por lo que el intercambio y la escucha activa a las necesidades diarias de los usuarios finales de la herramienta resulta fundamental en la etapa de apropiación.

En este punto, también deben considerarse los distintos niveles a los que la información puede ser relevante, para lo cual se recomienda contar con distintos tipos de usuarios, ya sea a nivel de reporte o a nivel de tablero de datos, para mejorar el uso de la información y promover la apropiación de la herramienta por parte de todo el sistema educativo. Por ejemplo, se pueden generar dos tipos de usuarios: uno con información desagregada a nivel de estudiante, dirigido a docentes, y otro con información consolidada a nivel de centro educativo, región y país, para directores y autoridades del nivel municipal, regional y central, promoviendo el uso de los datos para la toma de decisiones eficiente, oportuna y a tiempo.

En aquellos casos en que las entidades encargadas de la política educativa recurren a terceros (ya sea empresas privadas, universidades, u otros organismos estatales) para el desarrollo del sistema de alerta temprana, resulta fundamental garantizar un proceso de transferencia y apropiación de carácter transparente, fluido y que involucre a los distintos actores del sector educativo que serán usuarios finales de la herramienta. En este sentido, resulta clave que el equipo técnico encargado del desarrollo del sistema pueda capacitar a los usuarios, de manera que estos puedan conocer los aspectos claves del modelo, el objetivo, la lógica sobre la cual arroja los resultados, cómo funciona y la forma en la que se debe interactuar con el sistema. Con ese fin, se sugiere preparar un manual del usuario que facilite la apropiación de la nueva herramienta .



A modo de ejemplo, cabe mencionar la experiencia reciente de Uruguay. Durante 2020 y la primera mitad de 2021, la Administración Nacional de Educación Pública (ANEP), en colaboración con la Universidad de la República y el BID, creó un sistema de alerta temprana basado en aprendizaje automático, a través del desarrollo de un modelo predictivo de desvinculación educativa para enseñanza media. El equipo técnico construyó nueve modelos para predicción temprana del riesgo de desvinculación en el primer y segundo grado de secundaria. Una vez validados los modelos, el equipo técnico encargado del desarrollo transfirió a la ANEP los códigos para el preprocesamiento de los datos y la generación de los modelos, así como también las interfaces de programación de aplicaciones (API, por sus siglas en inglés),¹⁶ desarrolladas para la ejecución de los modelos, para que se implementaran como parte de su sistema de protección de trayectorias. En este proceso de transferencia y apropiación también se realizaron talleres con los diferentes funcionarios relacionados en alguna o varias etapas del proceso de definición del sistema de alerta temprana implementado.

Monitoreo y evaluación

Al igual que la mayoría de los sistemas de soporte y toma de decisiones, los sistemas de alerta temprana deben implementar un proceso de seguimiento y monitoreo para garantizar que la herramienta siga proporcionando resultados relevantes y no se desvíe de su objetivo previsto. Por tal razón, es importante definir métricas e indicadores de desempeño que permitan detectar, a lo largo del uso, las potenciales desviaciones o cambios inesperados en el funcionamiento del sistema. Para los sistemas basados en el aprendizaje automático, es particularmente crítico establecer métricas y umbrales de desempeño claros. Debido a que los algoritmos continúan aprendiendo después de que han sido desarrollados, es posible que se desvíen del concepto original y produzcan resultados diferentes, lo cual podría significar la necesidad de hacer un reentrenamiento del sistema.

La evaluación de un sistema de alerta temprana consiste específicamente en medir la precisión y calidad de la herramienta para detectar estudiantes en riesgo de exclusión educativa. Para esto, es fundamental realizar un seguimiento de las métricas establecidas en el modelado y de los umbrales de corte definidos para sistemas basados en conocimiento experto, así como la revisión de los supuestos de la captura de datos para asegurarse de que no hayan cambiado. Es decir, si por alguna u otra razón la cobertura, representatividad o calidad de los datos se ha modificado, esto cambiaría la forma en que funciona el sistema, por lo que el seguimiento, la evaluación y la actualización de estos sistemas resultan indispensables.

16. El término API es una abreviatura de *Application Programming Interfaces*; se trata de un conjunto de definiciones y protocolos que se utiliza para desarrollar e integrar el *software* de las aplicaciones.



Ahora bien, cabe recordar que un sistema de alta precisión que permita identificar adecuadamente a los estudiantes en riesgo de exclusión educativa solo será de utilidad si las intervenciones que se desencadenan a partir del mismo son efectivas y logran cumplir su objetivo de disminuir la exclusión. Es decir, que el sistema de alerta sea más o menos exitoso en identificar correctamente a los estudiantes en riesgo no significa que la intervención de política aplicada para reducir la exclusión vaya a ser exitosa. Por lo tanto, para evaluar el impacto de un sistema de protección de trayectorias en la disminución de la exclusión educativa, es necesario evaluar el impacto de la intervención de política, por ejemplo, cómo los programas de tutorías y acompañamiento implementados han logrado reducir la exclusión educativa.

Para ello, existen diversas técnicas de evaluación de impacto, como los experimentos naturales, los experimentos aleatorios controlados y los cuasi experimentos (Shadish, Cook y Campbell, 2002). En un experimento aleatorio controlado realizado por Mathematica se evaluó la efectividad de un proyecto piloto de prevención del abandono escolar usando alertas tempranas en cuatro países asiáticos: Camboya, India, Tayikistán y Timor Leste. Cada uno de estos países utilizó predictores personalizados para identificar a los estudiantes en riesgo más un diseño intervenciones/actividades diferenciadas como respuesta a la alerta, y en cada uno se realizó una evaluación de impacto independiente. Aunque las intervenciones tenían el mismo objetivo, prevenir la deserción escolar, estas fueron diversas: desde programas de tutoría extracurricular en Tayikistán hasta programas de alfabetización informática en Camboya y programas estructurados de recreación en India y Timor Leste. La evaluación de impacto arrojó los siguientes resultados: i) en tres de los cuatro países se mejoró la asistencia en términos del porcentaje de días de asistencia a la escuela entre los estudiantes del grupo de intervención en alrededor de 1,4 puntos porcentuales en promedio; ii) en Camboya las tasas de desvinculación escolar se redujeron del 41,1% en el grupo de control al 38,7% y al 39,3% en cada grupo de tratamiento (USAID, 2015).

Gracias a su alto nivel de validez, los experimentos aleatorios controlados se perciben como uno de los métodos recomendados para medir el impacto, pero la factibilidad de realizar este tipo de experimentos depende de la disponibilidad de datos de cada proyecto, ya que podría ser difícil contar con contrafactuales sólidos. En el paso 3 de la serie, que profundiza sobre intervenciones oportunas y estrategias de remediación, se presentan aspectos clave referidos a la etapa de evaluación de las acciones de política implementadas.



3.5 Rendición de cuentas

A fin de garantizar la transparencia, a lo largo de la implementación de intervenciones de política pública existe la necesidad de proporcionar información a la ciudadanía o a la población objetivo. Cuando ponen en marcha modelos de alerta temprana, los sistemas educativos deben tener la capacidad de explicar los procesos de toma de decisiones que los llevan a asignar recursos e intervenciones para algunos estudiantes –aquellos que se encuentren en riesgo de desvinculación escolar– y no para otros. Esto es en particular relevante cuando se habla de sistemas que utilizan aprendizaje automático.

Cuando un sistema de alerta temprana no identifica a un estudiante que está en riesgo de desvinculación, a pesar de estarlo (un falso negativo), o cuando un estudiante es asignado en la intervención de políticas sin estar en riesgo (un falso positivo), se evidencia, por un lado, una asignación ineficiente de recursos y, por otro, un potencial incremento del riesgo de interrupción de las trayectorias educativas de estos estudiantes, en particular en el caso del falso negativo. En este escenario, los docentes necesitan tener la capacidad de identificar qué estudiantes están en riesgo, pero también comprender por qué un estudiante lo está, para poder brindar las mejores intervenciones y prestaciones (Bowers, 2021).

En los sistemas basados en conocimiento experto, ese proceso es mucho más directo, porque existen umbrales previamente establecidos y conocidos por la comunidad educativa, lo cual favorece la rendición de cuentas y la interpretabilidad de los resultados. Sin embargo, cuando se utilizan sistemas de aprendizaje automático, aunque estos suelen tener un mejor rendimiento (menos errores de asignación), debido a la complejidad de su diseño, los datos son mucho más difíciles de interpretar (Sansone, 2019). Este *tradeoff* entre rendimiento e interpretabilidad adquiere un peso relevante en lo que atañe a la adopción y el uso de sistemas de alerta temprana sofisticados dentro de los distritos escolares (Knowles, 2015).

Debido a que los sistemas de aprendizaje automático suelen agregar diversos tipos de datos de estudiantes en múltiples áreas (comportamiento, asistencia, rendimiento académico, etc.) y aplican métodos estadísticos altamente avanzados para producir la predicción de riesgo, el docente no tiene información explícita de cómo el modelo llegó a la estimación (Coleman, 2021). Se trata de un desafío en términos de explicabilidad que es propio de los sistemas de toma de decisiones basados en aprendizaje automático. Sin embargo, existen técnicas estadísticas¹⁷ que analizan cómo funciona el modelo para predicciones individuales y facilitan la interpretabilidad de las alertas tempranas sin sacrificar la precisión, lo que también favorece el diseño de intervenciones estudiantiles más personalizadas (Coleman, 2021).

17. Para mayor información, se recomienda revisar *Uso responsable de IA para política pública: manual de ciencia de datos* (González, Ortiz y Sánchez, 2020) y las referencias mencionadas en dicho manual.



4 Próximos pasos

El paso 2 para la construcción de sistemas de protección de trayectorias educativas presenta las diferentes aproximaciones para diseñar sistemas de alerta temprana y profundiza sobre aspectos clave para la construcción de un sistema efectivo, al tiempo que describe características críticas relacionadas con el uso de los datos, la definición de indicadores y la potencial aplicación de la IA en este proceso.

Las siguientes dos entregas de esta serie tienen como objetivo continuar ahondando en las distintas temáticas relacionadas con el diseño y la implementación de sistemas de protección de trayectorias educativas. Así, el paso 3 se enfoca en intervenciones oportunas para la protección de trayectorias educativas, con la exposición de evidencia sobre intervenciones efectivas para disminuir la exclusión y buenas prácticas para intervenciones oportunas de remediación y acompañamiento. Por último, el paso 4 recoge una selección de experiencias de sistemas de protección de trayectorias en ALC, y aporta una síntesis de lo que se ha realizado tanto en materia de sistemas de alerta temprana como de intervenciones oportunas y estrategias de remediación.



Bibliografía

Adelman, M., F. Haimovich, A. Ham y E. Vázquez. 2017. Predicting School Dropout with Administrative Data: New Evidence from Guatemala and Honduras. Documento de trabajo de investigación de políticas No. 8142. Washington, D.C.: Banco Mundial.

Adelman, M. A. y M. Székely. 2017. An Overview of School Dropout in Central America: Unresolved Issues and New Challenges for Education Progress. *European Journal of Educational Research*, 6(3): 235-259.

Aguiar, E., H. Lakkaraju, N. Bhanpuri, D. Miller, B. Yuhas, K. Addison y R. Ghani. 2015. Who, When, and Why: A Machine Learning Approach to Prioritizing Students at Risk of not Graduating High School on Time. ACM International Conference Proceeding Series, Vol. 16-20-March-2015: 93-102.

ANEP (Administración Nacional de Educación Pública). 2021. Consultoría sobre estudiantes aprobados y no aprobados en escuelas urbanas y rurales de Uruguay. Montevideo: ANEP.

Arias Ortiz, E., J. Eusebio, M. Pérez Alfaro, M. Vásquez y P. Zoido. 2019. Del papel a la nube: Cómo guiar la transformación digital de los Sistemas de Información y Gestión Educativa (SIGED). Washington, D.C.: BID. Disponible en: <https://doi.org/10.18235/0001749>.

----- . 2021. *Los Sistemas de Información y Gestión Educativa (SIGED) de América Latina y el Caribe: la ruta hacia la transformación digital de la gestión educativa*. Washington, D.C.: BID. Disponible en: <https://publications.iadb.org/es/los-sistemas-de-informacion-y-gestion-educativa-siged-de-america-latina-y-el-caribe-la-ruta-hacia>.

Balfanz, R. 2008. Three steps to building an early warning and intervention system for potential dropouts. PowerPoint slides. Baltimore, MD: Center for Social Organization of Schools, Johns Hopkins University. Disponible en: jhu.edu/CSOS/graduation-gap/gradgap.html.

Berens, J., S. Oster, K. Schneider y J. Burghoff. 2018. Early Detection of Students at Risk: Predicting Student Dropouts Using Administrative Student Data and Machine Learning Methods. Schumpeter Discussion Papers, No. 2018-006.

Bowers, A. J., R. Sprott y S. Taff. 2013. Do We Know Who Will Drop Out? A Review of the Predictors of Dropping out of High School: Precision, Sensitivity and Specificity. *The High School Journal*. Disponible en: <https://doi.org/10.1353/hsj.2013.0000>.



Bowers, A. J. 2021. Early Warning Systems and Indicators of Dropping Out of Upper Secondary School: The Emerging Role of Digital Technologies. En: OCDE, *Smart Data and Digital Technology in Education: Learning Analytics, AI and Beyond*. París: OCDE.

Bruce, M., J. M. Bridgeland, J. H. Fox y R. Balfanz. 2011. On Track for Success: The Use of Early Warning Indicator and Intervention Systems to Build a Grad Nation. Civic Enterprises.

Cohen, A. 2017. Analysis of student activity in web-supported courses as a tool for predicting dropout. *Educational Technology Research & Development*, 65(5): 1285-1304. Disponible en: <https://doi.org/10.1007/s11423-017-9524-3>.

Coleman, C. 2021. Exploring a Generalizable Machine Learned Solution for Early Prediction of Student At-Risk Status. Tesis presentada ante la Universidad de Columbia. Disponible en: <https://doi.org/10.7916/d8-5scb-n214>.

Costa, F. J. , M. S. Bispo y R. F. C Pereira. 2018 . Dropout and retention of undergraduate students in management: a study at a Brazilian Federal University. *RAUSP Management Journal*, 53, 74-85.

Denis, G., M. Hermosilla, C. Aracena, R. Sánchez Ávalos, N. González Alarcón y C. Pombo. 20021. Uso responsable de IA para política pública. Manual de formulación de proyectos. Washington, D.C: BID. Disponible en: <https://publications.iadb.org/es/uso-responsable-de-ia-para-politica-publica-manual-de-formulacion-de-proyectos>

Departamento de Educación de Estados Unidos. 2016. Issue Brief: Early Warning Systems. Office of Planning, Evaluation and Policy Development. Washington, D.C.: Departamento de Educación de Estados Unidos. Disponible en: <https://www2.ed.gov/rschstat/eval/high-school/early-warning-systems-brief.pdf>.

Frazelle, S. y A. Nagel. 2015. A practitioner's guide to implementing early warning systems (REL 2015-056). Washington, D.C.: Departamento de Educación de Estados Unidos, Institute of Education Sciences, National Center for Education Evaluation and Regional Assistance, Regional Educational Laboratory Northwest. Disponible en: <http://ies.ed.gov/ncee/edlabs/projects/project.asp?ProjectID=396>.

González, F., T. Ortiz y R. Sánchez. 2020. *Uso responsable de IA para política pública: manual de ciencia de datos*. Washington, D.C.: BID. Disponible en: <https://publications.iadb.org/es/ia-responsable-manual-tecnico-ciclo-de-vida-de-la-inteligencia-artificial>.

Iam-On, N. y T. Boongoen. 2017. Generating descriptive model for student dropout: a review of clustering approach. En: *Human-centric Computing and Information Sciences*. Disponible en: <https://hcis-journal.springeropen.com/articles/10.1186/s13673-016-0083-0>.



Jimerson, S., B. Egeland, L. A. Sroufe y B. Carlson. 2000. A Prospective Longitudinal Study of High School Dropouts Examining Multiple Predictors Across Development. *Journal of School Psychology*, 38(6): 525-549. Disponible en: [https://doi.org/10.1016/S0022-4405\(00\)00051-0](https://doi.org/10.1016/S0022-4405(00)00051-0).

Josephson, K., R. Francis y S. Jayaram. 2018. Políticas para promover la culminación de la educación media en América Latina y el Caribe. Lecciones desde México y Chile. Caracas: CAF. Disponible en: <https://scioteca.caf.com/handle/123456789/1246>.

Knowles, J. E. 2015. Of Needles and Haystacks: Building an Accurate Statewide Dropout Early Warning System in Wisconsin. *Journal of Educational Data Mining*, 7(3): 18-67.

Lamb, S., E. Markussen, R. Teese, N. Sandberg y J. Polesel. 2010. School dropout and completion: International comparative studies in theory and policy. Berlín: Springer Science & Business Media.

Mac Iver, M. A. y D. J. Mac Iver. 2009. Beyond the Indicators: An Integrated School-Level Approach to Dropout Prevention. Washington, D.C.: George Washington University Center for Equity and Excellence in Education.

Manacorda, M. 2006. Grade Failure, Drop out and Subsequent School Outcomes: Quasi-Experimental Evidence from Uruguayan Administrative Data. Londres: STICERD. (Documento mimeografiado.)

Márquez, V., A. Cano, C. Romero, A. Mohammad, H. Mousa Fardoun y S. Ventura. 2016. Early dropout prediction using data mining: a case study with high school students. *Expert Systems*. Disponible en: <https://onlinelibrary.wiley.com/doi/10.1111/exsy.12135>.

Muñoz Stuardo, G. 2020. Sistematización de antecedentes, principales características e implementación del SPTE: fortalezas, debilidades y desafíos para su continuidad y fortalecimiento. Consultoría de Sistematización de la implementación del Sistema de Protección de Trayectorias Educativas (SPTE) del Uruguay.

OCDE (Organización para la Cooperación y el Desarrollo Económicos). 2019. Artificial Intelligence in Society. París: OCDE.

Pombo, C., M. Cabrol, N. González Alarcón y R. Sánchez Ávalos. 2020. fAIr LAC: Adopción ética y responsable de la inteligencia artificial en América Latina y el Caribe. Washington, D.C.: BID. Disponible en: <http://dx.doi.org/10.18235/0002169>.

Prenkaj, B., P. Velardi, G. Stilo, D. Distanto y S. Faralli. 2020. A Survey of Machine Learning Approaches for Student. *ACM Computing Surveys*.



Rivera Pizarro, J. 2020. Sistemas de alerta temprana en la región SICA: Revisión de la literatura y de la práctica. San José: SICA. Disponible en: <https://ceccsica.info/sites/default/files/inline-files/SIS-TEMAS%20DE%20ALERTA%20TEMPRANA%20EN%20LA%20REGI%C3%93N%20SICA.pdf>.

Román, M. 2013. Factores asociados al abandono y la deserción escolar en América Latina: Una mirada en conjunto. *Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación (REICE)*, 11(2): 33-59.

Rumberger, R. W. 2012. *Dropping Out: Why Students Drop Out of High School and What Can Be Done About It* (Reprint edition). Cambridge, MA: Harvard University Press.

Sansone, D. 2019. Beyond Early Warning Indicators: High School Dropout and Machine Learning. *Oxford Bulletin of Economics & Statistics*. Disponible en: DOI 10.1111/obes.12277.

Sattar, A., F. Mahtab, C. Ratna y R. Chandan. 2016. Survival Analysis based Framework for Early Prediction of Student Dropouts. *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management (CIKM)*, 16: 903-912. Disponible en: <https://doi.org/10.1145/2983323.2983351>.

Shadish, W. R., T. D. Cook y D. T. Campbell. 2002. *Experimental and quasi-experimental designs for generalized causal inference*. Boston, MA: Houghton, Mifflin and Company.

UNICEF (Fondo de las Naciones Unidas para la Infancia). 2018. *Early Warning Systems for Students at Risk of Dropping Out: Policy and Practice Pointers for Enrolling All Children and Adolescents in School and Preventing Dropout*. UNICEF Series on Education Participation and Dropout Prevention, Vol. 2. Nueva York, NY: UNICEF.

-----, 2020. *Proteger trayectorias educativas de niñas, niños y adolescentes para mejorar los aprendizajes y la eficiencia del sistema educativo*. Nueva York, NY: UNICEF.

University of Chicago Consortium on Chicago School Research. 2014. *Selecting effective indicators*. College Readiness Indicator Systems Resource Series. Seattle, WA: Fundación Bill & Melinda Gates.

USAID (Agencia de los Estados Unidos para el Desarrollo Internacional). 2015. *Do Early Warning Systems and Student Engagement Activities Reduce Dropout? Findings from the Four-Country SDPP Evaluation*. Washington, D.C.: USAID School Dropout Prevention Summit.

