

INTELIGENCIA ARTIFICIAL...



EXPERIENCIAS Y REFLEXIONES
SOBRE LA INVESTIGACIÓN EDUCATIVA

ALEXANDRO ESCUDERO-NAHÓN
EMMA PATRICIA MERCADO-LÓPEZ
(Eds.)

Transdigital[®]
editorial

INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN EDUCATIVA

ALEXANDRO ESCUDERO-NAHÓN

EMMA PATRICIA MERCADO-LÓPEZ

(Eds.)

ABRAHAM VEGA TAPIA, ADRIÁN SALVADOR RIVERA LIMA, ADRIANA ERÉNDIRA MURILLO, AILÉN IDA STRANGES, ALAN ISAAC TRINIDAD GONZÁLEZ, ALDO ESAÚ RODRÍGUEZ GUEVARA, ALEJANDRA YOHANA VERGARA AVALOS, ALEXANDRO ESCUDERO-NAHÓN, ALFREDO MARÍN MARÍN, ALICIA ANGÉLICA NÚÑEZ URBINA, ANA LILIA LAUREANO-CRUCES, ANABEL PALACIOS MARTÍNEZ, ARTURO DURÁN BENVAINDES, ARTURO GONZÁLEZ TORRES, CARLOS ALFONSO VALENZUELA MALDONADO, CARLOS VALENTÍN CORDOVA SERNA, CARMEN C. ORTEGA HERNÁNDEZ, CHRISTIAN JONATHAN ANGEL RUEDA, CLAUDIA RITA ESTRADA ESQUIVEL, CLAUDIA SELENE TAPIA RUELAS, CRISTIAN ALEJANDRO RUBALCAVA DE LEÓN, DANIEL DIAZ-ROJAS, DANIEL AYALA NIÑO, DAVID XICOTÉNCATL RUEDA LÓPEZ, DORA MARÍA LLADÓ LÁRRAGA, EDGAR OLIVER CARDOSO ESPINOSA, EDUARDO ARANGO HERRERA, ELENA FABIOLA RUIZ LEDESMA, ENRIQUE ISMAEL MELÉNDEZ RUIZ, FRANCISCA YEDID ZAVALA ÁLVAREZ, FRANCISCO RAÚL CASAMADRID PÉREZ, GABRIELA RUIZ DE LA TORRE, GERARDO QUIROZ BOJORGES, GILBERTO ACOSTA CASTAÑEDA, GILBERTO ISRAEL GONZÁLEZ ORDAZ, GLORIA ANGÉLICA RODRÍGUEZ MEJÍA, HERLINDA SAUCEDO CASTILLO, HIPÓLITO GÓMEZ AYALA, IRENE AGUILAR JUÁREZ, ISIDRO AMARO RODRÍGUEZ, ISMAEL MARTÍNEZ-BONILLA, ISOLINA GONZÁLEZ CASTRO, ISRAEL GARDUÑO-BONILLA, JENY HAIDEÉ ESPINOSA BARAJAS, JÉSICA ALHELÍ CORTÉS RUIZ, JESÚS ARCE LANDA, JOEL AYALA DE LA VEGA, JOSÉ LUIS BORGES UCÁN, JUAN SALVADOR HERNÁNDEZ VALERIO, JUANA HERNÁNDEZ-CHAVARRÍA, KAREN QUINTERO ÁLVAREZ, KAREN VALENTINA MARIEL VILLAGRÁN, KATHIANE TOLEDO VALDEZ, LAURA DE J. VELASCO ESTRADA, LIZETTE RIVERA LIMA, LORENA ALICIA MEDINA LÓPEZ, LUCIA MORALES MORALES, LUIS ANDRÉS RODRÍGUEZ-CORRAL, MAGALLY MARTÍNEZ REYES, MARCO POLO MENDOZA OTERO, MARÍA GUADALUPE PÉREZ-MARTÍNEZ, MARÍA ISABEL ARREOLA CARO, MARÍA ISABEL HERNÁNDEZ ROMERO, MARÍA LORCY ROSERO-MORA, MARTHA ALEJANDRINA ZAVALA GUIRADO, MARTHA SUSANA BRAUER AGUILAR, MARTIN JOAQUIN AGUILAR MUÑOZ, MAURICIO HERNÁNDEZ RAMÍREZ, MELISSA BLANQUETO ESTRADA, MELISSA EDITH SALAZAR ECHEAGARAY, MIGUEL ANGEL GARCÍA-MÁRQUEZ, MOISÉS ANTÚNEZ GARCÍA, NOÉ ALEJANDRO CASTRO SÁNCHEZ, OSCAR JARDEY SUÁREZ, PAOLA EDUVINA GRAJEDA ARGUIJO, PATRICIA JANET PADILLA-ORNELAS, PAVEL DAVID ULISES AVENDAÑO LÓPEZ, RAFAEL ALEJANDRO ZAVALA CARRILLO, RAMÓN VENTURA ROQUE HERNÁNDEZ, RAQUEL MONDRAGÓN HUERTA, RAÚL ARTURO ALVARADO LÓPEZ, RENATA AGUILAR RODRÍGUEZ, REYNA MORENO BELTRÁN, RICARDO CHAPARRO-SÁNCHEZ, RITA SALAZAR, ROSA MARÍA RIVAS GARCÍA, SERGIO RODRÍGUEZ AYALA, SONIA VILLAGRÁN RUEDA, SUSANA VEGA LEAL, TERESA CASTRO MATA, ULISES TAMEZ-DUQUE, VIANEY RIOS ROMERO, VITERVO LÓPEZ CABALLERO, YAZMIN LISSSET MEDEL SAN ELÍAS, YEN VENTURA GONZÁLEZ, YULIANA TSUNAMI ALMAGUER LEAL Y ZITA VALDÉS.

AUTORES Y AUTORAS

Título original: Inteligencia artificial: experiencias y reflexiones sobre la investigación educativa / Alexandro Escudero-Nahón y Emma Patricia Mercado-López (Eds.) — Ciudad de Querétaro, México: Editorial Transdigital, 2026 — 545 páginas.

International Standard Book Number (ISBN): 978-968-9724-22-3.

Digital Object Identifier (DOI) del libro: <https://doi.org/10.56162/transdigitalbc13>

Clasificación DEWEY. Materia: 370.7—Estudio y enseñanza de la educación. Tipo de Contenido: Libros universitarios.
Clasificación thema: JN—Educación. Tipo de soporte: libro digital gratuito descargable. Formato: PDF. Tamaño: 6.6 Mb.



Este libro es una publicación de acceso abierto con los principios de Creative Commons Attribution 4.0 International License (CC BY-NC-SA). Esta licencia permite a los reutilizadores distribuir, remezclar, adaptar y desarrollar el material en cualquier medio o formato únicamente con fines no comerciales y siempre que se otorgue la atribución al creador. Si remezcla, adapta o construye sobre el material, debe licenciar el material modificado bajo términos idénticos.

Esta obra ha sido dictaminada por pares académicos expertos con el método de doble ciego. Los dictámenes están resguardados en los archivos de la Editorial *Transdigital*.

D.R. 2026 Alexandro Escudero-Nahón y Emma Patricia Mercado-López (Eds.).

D.R. 2026 Autores y autoras.

D.R. 2026 Sello Editorial *Transdigital*.



Sociedad de Investigación sobre Estudios Digitales, S. C. Nombre de marca: *Transdigital*. Dirección: Circuito Altos Juriquilla 1132. Colonia Altos Juriquilla. C. P. 76230, Juriquilla, Querétaro, México. +52 (442) 301 32 38. editorial@transdigital.mx www.editorial.transdigital.mx



Registro en el Padrón Nacional de Editores como agente editor Sociedad de Investigación sobre Estudios Digitales, S. C., con el Dígito Identificador 978-607-99594.



Afiliación a la Cámara Nacional de la Industria Editorial Mexicana (CANIEM) con el número 4069, de conformidad con el artículo 17 de la Ley de Cámaras Empresariales y sus Confederaciones en vigor.

Registro Nacional de Instituciones y Empresas Científicas y Tecnológicas de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) de México con el folio: RENIECYT 2400068.



Sugerencia de referencia para el libro en APA 7a. edición:

Escudero-Nahón, A., & Mercado-López, E. P. (2026) (Eds.). *Inteligencia artificial: experiencias y reflexiones sobre la investigación educativa*. Editorial Transdigital. <https://doi.org/10.56162/transdigitalbc13>

CONTENIDO

00.	LA CONVULSA INCORPORACIÓN DE LA INTELIGENCIA ARTIFICIAL EN ÁMBITOS EDUCATIVOS	11
	Alexandro Escudero-Nahón y Daniel Diaz-Rojas	
01.	PROPUESTA METODOLÓGICA PARA EL DISEÑO DE UN ATLAS DE INTELIGENCIA ARTIFICIAL EN INSTITUCIONES DE EDUCACIÓN SUPERIOR	25
	Carmen C. Ortega Hernández, Laura de J. Velasco Estrada y Kathiane Toledo Valdez	
02.	SISTEMATIZACIÓN DE EXPERIENCIAS EN APRENDIZAJE-SERVICIO: NUEVAS RUTAS PARA EL ANÁLISIS DE INFORMACIÓN MEDIANTE INTELIGENCIA ARTIFICIAL	48
	María Isabel Arreola Caro, Susana Vega Leal y Abraham Vega Tapia	
03.	LA INTEGRACIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA ENSEÑANZA-APRENDIZAJE: PERSONALIZACIÓN, EQUIDAD E INCLUSIÓN.....	65
	Elena Fabiola Ruiz Ledesma y Alan Isaac Trinidad González	
04.	INTELIGENCIA ARTIFICIAL GENERATIVA EN LA PLANEACIÓN DIDÁCTICA DE ESTUDIANTES NORMALISTAS: UN ESTUDIO EXPLORATORIO EN UNA ESCUELA NORMAL MEXICANA	76
	Moisés Antúnez García, Sergio Rodríguez Ayala, Aldo Esaú Rodríguez Guevara, Carlos Valentín Córdova Serna y Rafael Alejandro Zavala Carrillo	
05.	INTELIGENCIA ARTIFICIAL GENERATIVA COMO HERRAMIENTA DE INNOVACIÓN EN INVESTIGACIÓN EDUCATIVA: UN ANÁLISIS CRÍTICO	98
	Pavel David Ulises Avendaño López, Arturo González Torres y Gerardo Quiroz Bojorges	
06.	ACTITUDES HACIA LA INTELIGENCIA ARTIFICIAL EN BACHILLERATO: ESTUDIO EN INSTITUCIONES DE MUNICIPIOS SEMIURBANOS DE CHIHUAHUA, MÉXICO	115
	Carlos Alfonso Valenzuela Maldonado	
07.	PRÁCTICA DOCENTE EN MUNDOS VIRTUALES: CONFIGURACIONES PEDAGÓGICAS ENTRE APROPIACIÓN Y DEPENDENCIA EN LA INTELIGENCIA ARTIFICIAL INMERSIVA	131
	Martin Joaquin Aguilar Muñoz, Christian Jonathan Angel Rueda , Ricardo Chaparro-Sánchez y Alexandro Escudero-Nahón	

08.		
	INTEGRACIÓN DE INTELIGENCIA ARTIFICIAL EN SIMULACIÓN CLÍNICA DE ENFERMERÍA: BENEFICIOS, RETOS Y EXPERIENCIA INSTITUCIONAL	146
	Teresa Castro Mata, Gilberto Acosta Castañeda y Paola Eduvina Grajeda Arguijo	
09.		
	USO Y PERCEPCIÓN DE INTELIGENCIA ARTIFICIAL EN CONTADURÍA PÚBLICA, SEGÚN GÉNERO, EN LA UNIVERSIDAD AUTÓNOMA DE TAMAULIPAS, MÉXICO.....	156
	Gloria Angélica Rodríguez Mejía, Cristian Alejandro Rubalcava de León, Enrique Ismael Meléndez Ruiz y Eduardo Arango Herrera	
10.		
	INTELIGENCIA ARTIFICIAL Y EDUCACIÓN SUPERIOR INCLUSIVA EN EL TECNOLÓGICO NACIONAL DE MÉXICO.....	169
	Renata Aguilar Rodríguez, Magally Martínez Reyes y Marco Polo Mendoza Otero	
11.		
	INTELIGENCIA ARTIFICIAL EN EL POSGRADO.....	186
	Edgar Oliver Cardoso Espinosa, Jéssica Alhelí Cortés Ruiz y Rosa María Rivas García	
12.		
	ACTITUDES HACIA LA INTELIGENCIA ARTIFICIAL DEL PROFESORADO EN FORMACIÓN DEL SUR DE COLOMBIA: INVESTIGACIÓN EN DESARROLLO.....	202
	Oscar Jardey Suárez, María Lorcý Rosero-Mora y Luis Andrés Rodríguez-Coral	
13.		
	EDUCACIÓN SUPERIOR EN LA ERA DIGITAL: ADOPCIÓN, SOBERANÍA INTELLECTUAL, SOSTENIBILIDAD Y DILEMAS ÉTICOS DE LA INTELIGENCIA ARTIFICIAL GENERATIVA	215
	Juana Hernández-Chavarría, Adriana Eréndira Murillo e Isidro Amaro Rodríguez	
14.		
	INTELIGENCIA ARTIFICIAL GENERATIVA Y APRENDIZAJE UNIVERSITARIO: CHATGPT Y SUS IMPLICACIONES COGNITIVAS	232
	Alicia Angélica Núñez Urbina y Herlinda Saucedo Castillo	
15.		
	IMPACTO DE LA INTELIGENCIA ARTIFICIAL GENERATIVA EN LA EDUCACIÓN SUPERIOR.....	247
	Alejandra Yohana Vergara Avalos, Raquel Mondragón Huerta y Juan Salvador Hernández Valerio	

16.	ALGORITMOS DE EMPATÍA: INTELIGENCIA ARTIFICIAL, ANDAMIAJE Y DESARROLLO DE HABILIDADES SOCIOEMOCIONALES EN LA EDUCACIÓN SUPERIOR.....	262
	Francisco Raúl Casamadrid Pérez, Gabriela Ruiz de la Torre y David Xicoténcatl Rueda López	
17.	ACTITUDES ESTUDIANTILES HACIA LA INTELIGENCIA ARTIFICIAL GENERATIVA Y SU IMPACTO EN LA EQUIDAD EDUCATIVA.....	278
	Dora María Lladó Lárraga, Jeny Haideé Espinosa Barajas y Mauricio Hernández Ramírez	
18.	INTELIGENCIA ARTIFICIAL GENERATIVA EN ESTUDIANTES DE POSGRADO: ANÁLISIS DEL USO Y SUS IMPLICACIONES ACADÉMICAS	294
	Francisca Yedid Zavala Álvarez, Martha Alejandrina Zavala Guirado, Claudia Selene Tapia Ruelas e Isolina González Castro	
19.	RETOS Y OPORTUNIDADES DEL EMPRENDIMIENTO UNIVERSITARIO ANTE LA INTELIGENCIA ARTIFICIAL.....	308
	Raúl Arturo Alvarado López	
20.	PERCEPCIONES DE LA INTELIGENCIA ARTIFICIAL EN LA EDUCACIÓN SUPERIOR: UN ESTUDIO DE VALIDACIÓN PSICOMÉTRICA.....	323
	Ramón Ventura Roque Hernández y Lorena Alicia Medina López	
21.	¿QUIÉN ABANDONARÁ MAÑANA? UN MODELO EXPLICABLE PARA ANTICIPAR LA DESERCIÓN EN INSTITUCIONES DE EDUCACIÓN SUPERIOR	339
	Yen Ventura González, Vitervo López Caballero, Lucia Morales Morales, Jesús Arce Landa y Noé Alejandro Castro Sánchez	
22.	ANÁLISIS DE LAS PERCEPCIONES DOCENTES ANTE LA INCORPORACIÓN DE CHATGPT EN LA EDUCACIÓN SUPERIOR.....	353
	Reyna Moreno Beltrán, Ailén Ida Stranges, Juan Salvador Hernández Valerio y Anabel Palacios Martínez	

23.		
	COMPETENCIAS DIGITALES CLAVE PARA LA ALFABETIZACIÓN EN INTELIGENCIA ARTIFICIAL: UN ESTUDIO DE CASO CON ESTUDIANTES UNIVERSITARIOS MEXICANOS	368
	Alfredo Marín Marín, María Isabel Hernández Romero, José Luis Borges Ucán y Melissa Blanqueto Estrada	
24.		
	EL DESARROLLO DEL PENSAMIENTO CRÍTICO EN LA GESTIÓN DEL CONOCIMIENTO EN LA EDUCACIÓN 4.0.....	385
	Gilberto Israel González Ordaz, Lizette Rivera Lima y Adrián Salvador Rivera Lima	
25.		
	BURNOUT DOCENTE E INTELIGENCIA ARTIFICIAL GENERATIVA: HACIA UN MODELO BIOPSIICOSOCIAL.....	399
	Ismael Martínez-Bonilla, Sonia Villagrán-Rueda y Karen Valentina Mariel-Villagrán	
26.		
	SISTEMAS DE TUTORÍA INTELIGENTE: EL CAMBIO Y TRANSICIÓN A LA INTELIGENCIA ARTIFICIAL GENERATIVA	412
	Ismael Martínez-Bonilla, Ana Lilia Laureano-Cruces e Israel Garduño-Bonilla	
27.		
	ANÁLISIS DEL USO Y LINEAMIENTOS ÉTICOS DE LA INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR MEXICANA	427
	Martha Susana Brauer Aguilar, Vianey Ríos Romero y Melissa Edith Salazar Echeagaray	
28.		
	CHATBOTS COMO MEDIADORES EN LA CONSTRUCCIÓN DEL CONOCIMIENTO EN LABORATORIO	444
	Ulises Tamez-Duque, Rita Salazar y Zita Valdés	
29.		
	INTELIGENCIA ARTIFICIAL VS. INTELIGENCIA ARTIFICIAL: HERRAMIENTAS DE DETECCIÓN APLICADAS A LA EVALUACIÓN EDUCATIVA.....	456
	Arturo Durán Benvaides, Claudia Rita Estrada Esquivel y Karen Quintero Álvarez	
30.		
	ANÁLISIS DEL USO EFECTIVO Y ÉTICO DE PROMPTS EN CHATGPT PARA EL DESARROLLO DE TAREAS UNIVERSITARIAS	472
	Raquel Mondragón Huerta, Reyna Moreno Beltrán y Yazmin Lisset Medel San Elías	

31.	
EL ARTE DE EXPANDIR EL PENSAMIENTO HUMANO EN LA ERA DE LA INTELIGENCIA ARTIFICIAL	486
Yuliana Tsunami Almaguer Leal	
32.	
LA BRECHA DIGITAL Y SU IMPACTO EN EL USO DE LAS HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL GENERATIVA EN LA EDUCACIÓN SUPERIOR DE MÉXICO	500
María Guadalupe Pérez-Martínez, Miguel Angel García-Márquez y Patricia Janet Padilla-Ornelas	
33.	
INTELIGENCIA ARTIFICIAL Y LOS LÍMITES DEL CONOCIMIENTO FORMAL: UNA PERSPECTIVA EPISTEMOLÓGICA Y EDUCATIVA.....	513
Joel Ayala de la Vega, Irene Aguilar Juárez, Daniel Ayala Niño y Hipólito Gómez Ayala	



21.

**¿QUIÉN ABANDONARÁ MAÑANA? UN MODELO
EXPLICABLE PARA ANTICIPAR LA DESERCIÓN EN
INSTITUCIONES DE EDUCACIÓN SUPERIOR**

YEN VENTURA GONZÁLEZ

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO (CENIDET), MÉXICO
ORCID: 0009-0005-6514-9417

VITERVO LÓPEZ CABALLERO

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO (CENIDET), MÉXICO
ORCID: 0000-0002-1942-9558

LUCIA MORALES MORALES

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO (CENIDET), MÉXICO
ORCID: 0009-0006-6593-4762

JESÚS ARCE LANDA

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO (CENIDET), MÉXICO
ORCID: 0000-0002-2052-3322

NOÉ ALEJANDRO CASTRO SÁNCHEZ

CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO (CENIDET), MÉXICO
ORCID: 0000-0002-8083-3891

DOI del capítulo del libro: <https://doi.org/10.56162/transdigitalbc13.21>

21.

¿QUIÉN ABANDONARÁ MAÑANA? UN MODELO EXPLICABLE PARA ANTICIPAR LA DESERCIÓN EN INSTITUCIONES DE EDUCACIÓN SUPERIOR

INTRODUCCIÓN

La educación superior constituye uno de los pilares fundamentales para el desarrollo sostenible, la competitividad económica y la formación de capital humano (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO], 2021). Sin embargo, la deserción estudiantil continúa siendo uno de los retos más persistentes en América Latina y particularmente en México. De acuerdo con datos reportados por la Organización para la Cooperación y el Desarrollo Económicos (OCDE) y retomados en estudios recientes, México presenta tasas acumuladas de abandono que oscilan entre el 30 y el 40% en la última década (Heffington et al., 2024).

La tasa de deserción en los programas de licenciatura en México para el ciclo escolar 2023-2024 fue de 7.1% (Secretaría de Educación Pública [SEP], 2025). En el caso del Tecnológico Nacional de México (TecNM), la institución de educación superior tecnológica más grande del país y con una matrícula superior a 567,000 estudiantes, la deserción alcanzó 10.74% durante ese mismo periodo. Para el ciclo 2024-2025, este indicador registró una ligera disminución, situándose en 8.96% (TecNM, 2024).

La deserción estudiantil no responde a una causa aislada, sino a la interacción de factores académicos, económicos y personales que se entrelazan a lo largo de la trayectoria formativa, como evidencia de ello en el contexto mexicano, estudios cuantitativos han identificado que la reprobación temprana, las limitaciones económicas y determinadas condiciones personales influyen de manera significativa en la decisión de abandono, particularmente durante los primeros semestres de la trayectoria académica (Heffington et al., 2024).

Paralelamente investigaciones internacionales recientes han destacado el potencial de los modelos estadísticos y de aprendizaje automático para identificar de forma anticipa-

da a estudiantes en riesgo de deserción. Variables como el rendimiento académico de los primeros semestres, la edad al momento de ingreso y el acceso a apoyos económicos han mostrado capacidad predictiva, observándose resultados que indican que la condición de becario puede reducir la probabilidad de abandono (Romero & Liao, 2025). No obstante, estos efectos deben interpretarse con cautela y atendiendo a las particularidades contextuales de cada institución.

Desde una perspectiva conceptual, modelos clásicos como el de la integración académica y social (Tinto, 1975) y el modelo de permanencia (Bean, 1982) continúan siendo referentes importantes para comprender el abandono estudiantil como un proceso progresivo de integración o desvinculación académica. Sin embargo, buena parte de los enfoques predictivos sustentados en datos administrativos organizados en cohortes temporales específicos, tal como se discute en revisiones recientes sobre inteligencia artificial (IA) aplicada a la educación superior (Bond et al., 2024). Esta forma de modelación tiende a capturar al estudiante en un momento determinado, lo que puede dificultar la comprensión de sus trayectorias individuales y de las dimensiones sociales e institucionales que influyen en su permanencia, particularmente en sistemas complejos y multicampus como el TecNM.

Se propone una arquitectura conceptual de modelo predictivo longitudinal multidimensional basado en inteligencia artificial explicable (XAI), orientado a su implementación en cortes específicas con potencial de escalamiento institucional del TecNM. El propósito de la propuesta es aportar al uso responsable y estratégico de la IA en la educación tecnológica superior, uniendo variables personales, académicas, psicológicas, institucionales y de bienestar a través del seguimiento temporal y de los métodos de explicabilidad algorítmica.

DESARROLLO

DE LA CLASIFICACIÓN DEL RIESGO A LA COMPRESIÓN PROCESUAL DEL ABANDONO

El desarrollo reciente de modelos predictivos en educación superior ha estado fuertemente influido por el avance de técnicas de aprendizaje automático y por la disponibilidad de grandes volúmenes de datos institucionales. Según Issah et al. (2023), las revisiones sistemáticas señalan que una proporción significativa de los estudios de predicción académica se apoya en variables administrativas tales como rendimiento previo, promedio acumulado, número de asignaturas reprobadas y características demográficas, empleando algoritmos supervisados para clasificar a los estudiantes según su probabilidad de éxito o

abandono. Estos enfoques han permitido mejorar el desempeño técnico de los modelos, particularmente en términos de métricas como exactitud, AUC o F1-score.

En el ámbito específico de la deserción, investigaciones recientes como la de Martínez y Castillo, (2024a) han utilizado registros académicos organizados por cortes semestrales para construir modelos de clasificación binaria a través de técnicas como Random Forests, Gradient Boosting o XGBoost aplicados a datos administrativos históricos. Otros estudios han demostrado que es posible identificar estudiantes en riesgo con niveles elevados de precisión a partir de información disponible en sistemas institucionales. Sin embargo, una tendencia metodológica frecuente tiende a representar el abandono como un resultado dicotómico: permanecer o desertar, esto modelado a partir de un conjunto relativamente acotado de variables observables (Bond et al., 2024; Issah et al., 2023).

Desde una perspectiva conceptual, esta representación puede simplificar un fenómeno que la literatura ha descrito como dinámico y acumulativo (Bean, 1982; Tinto, 1975). Los modelos clásicos de permanencia han planteado que el abandono no emerge como un evento aislado, sino como resultado de interacciones progresivas entre dimensiones académicas, sociales e institucionales que evolucionan a lo largo del tiempo. Cuando la predicción se estructura exclusivamente en torno a cohortes temporales específicos, se corre el riesgo de capturar el estado del estudiante en un momento determinado, sin modelar las variaciones individuales a lo largo del recorrido académico que configuran el proceso de desvinculación académica. Esta limitación resulta especialmente relevante cuando factores como la motivación y el compromiso muestran patrones evolutivos asociados con la persistencia o el abandono estudiantil (Eegdeman et al., 2025)

Estudios actuales han comenzado a incorporar datos en múltiples puntos temporales para captar patrones evolutivos en el desempeño estudiantil tal como lo señala Seo et al. (2024). No obstante, la integración sistemática de dimensiones académicas, psicológicas, institucionales y contextuales dentro de arquitecturas longitudinales coherentes aún representa un desafío metodológico y conceptual.

Si bien la precisión algorítmica es necesaria para estimar riesgos con consistencia técnica, no resulta suficiente para comprender las complejidades del abandono académico ni para orientar decisiones pedagógicas responsables, como ha sido señalado en análisis recientes sobre los desafíos conceptuales y éticos en la IA aplicada a la educación (Bond et al., 2024). Más allá de una clasificación con resultado binario o de categorías de riesgo es

fundamental integrar diferentes niveles de análisis como académico, psicosocial e institucional, de tal manera que permitan interpretar y comprender el abandono como un proceso dinámico configurado progresivamente por factores interdependientes. Este desplazamiento conceptual no implica descartar los avances de la ciencia de datos educativa, sino que trata de ampliar su alcance analítico para que los resultados predictivos se integren a la reflexión pedagógica y orienten las decisiones académicas.

INTELIGENCIA ARTIFICIAL EXPLICABLE Y GOBERNANZA EN LA ANALÍTICA EDUCATIVA

La incorporación de modelos predictivos en educación superior no plantea únicamente desafíos técnicos, sino también algunas interrogantes institucionales sobre la forma de interpretación y del uso de los resultados generados por sistemas algorítmicos. En contextos donde las decisiones derivadas por estos modelos pueden influir en las experiencias educativas individuales, resulta indispensable establecer marcos claros de responsabilidad, supervisión y transparencia, en consonancia con los principios de ética y gobernanza de la IA promovidos por la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura ([UNESCO], 2022).

En este sentido, la gobernanza de la IA y de la analítica educativa requiere establecer marcos sólidos de transparencia, supervisión humana y responsabilidad institucional que guíen el empleo de modelos predictivos en el aula (UNESCO, 2022). La literatura reciente subraya que la gobernanza de la IA en educación superior debe estructurarse en torno a principios de transparencia, supervisión humana y rendición de cuentas, integrando lineamientos claros sobre el uso de datos, equidad y responsabilidad académica (Barus et al., 2025). La explicabilidad algorítmica se convierte en un componente clave de la gobernanza, al permitir que los resultados del modelo sean interpretables, auditables y coherentes con los principios institucionales que regulan la toma de decisiones académicas. Asimismo meta-revisiones recientes advierten que el uso de IA en educación superior requiere marcos de gobernanza que integren transparencia, responsabilidad institucional y equidad especialmente cuando los sistemas predictivos influyen en decisiones académicas y administrativas (Bond et al., 2024)

Bajo este escenario, la explicabilidad algorítmica adquiere un papel central. No basta con un modelo que alcance altos niveles de exactitud; sino más bien es necesario comprender cómo y por qué genera determinadas estimaciones. El reto verdadero consiste en entender las razones que llevaron al modelo a emitir dicha predicción. En ese sentido XAI

ha surgido como un campo orientado precisamente a desarrollar métodos que permitan interpretar el funcionamiento interno de modelos complejos, favoreciendo su transparencia y auditabilidad.

Investigaciones recientes en predicción han incorporado análisis de importancia de variables y estrategias de interpretación para comprender que factores académicos y contextuales influyen con mayor peso en los resultados predictivos (Rabelo & Zárate, 2025). Estos trabajos muestran que es posible combinar buen desempeño predictivo con mecanismos que permitan comprender la contribución relativa de los distintos factores. Sin embargo, en muchos casos la explicabilidad continúa siendo un análisis complementario posterior al entrenamiento del modelo, más que un componente integrado desde el diseño conceptual de la arquitectura analítica.

Desde esta perspectiva, avanzar hacia una analítica educativa responsable implica asumir la explicabilidad no como un añadido técnico, sino como una condición que acople precisión predictiva, interpretación pedagógica y responsabilidad institucional. De lo contrario, existe el riesgo de que la clasificación del riesgo se traduzca en procesos de etiquetamiento simplificados o en decisiones automatizadas desvinculadas del acompañamiento académico.

IMPLICACIONES EPISTEMOLÓGICAS DEL ENFOQUE LONGITUDINAL EN LA ANALÍTICA EDUCATIVA

Incorporar una perspectiva longitudinal en el análisis del abandono académico no significa únicamente añadir más puntos de medición o extender el horizonte temporal de los datos. Esto implica revisar la forma en que se concibe la experiencia estudiantil dentro de los sistemas de educación superior. Cuando los modelos se construyen a partir de cohortes aislados, el estudiante puede quedar representado como una instantánea estadística. Esta representación puede ser útil para clasificar, pero resulta limitada para comprender procesos que se configuran gradualmente.

La literatura reciente de IA y analítica educativa indica que muchos estudios han priorizado la precisión predictiva por encima de la comprensión de las dinámicas temporales que conforman las decisiones de permanencia o abandono estudiantil. Como ejemplo de ello una, revisión sistemática reciente sobre aplicaciones de IA en educación señala que los desarrollos tecnológicos enfrentan retos no solo técnicos, sino también éticos y de despliegue contextual en entornos reales de aprendizaje (Matos et al., 2025)

En este sentido, la metodología longitudinal permite observar cómo se configuran y evolucionan factores académicos, socioeconómicos y motivacionales a través del tiempo, capturando efectos acumulativos que las evaluaciones transversales no revelan. No basta con generar estimaciones de riesgo, es crucial que estas estimaciones sean comprensibles y contextualizadas para los equipos académicos que tomarán decisiones pedagógicas (Gunasekara & Saarela, 2025).

La necesidad de integrar explicabilidad en sistemas predictivos también ha sido resaltada en estudios concretos de predicción de abandono. Por ejemplo, investigaciones recientes han desarrollado marcos que combinan algoritmos de aprendizaje automático con técnicas explicables como SHAP para interpretar las contribuciones de las variables en las predicciones de riesgo de abandono, mostrando que este tipo de enfoques permiten no solo identificar estudiantes en riesgo, sino sugerir posibles factores subyacentes de forma interpretable (Nti & Ramanayake, 2025).

Asimismo, trabajos aplicados en educación superior han utilizado técnicas híbridas que combinan modelos predictivos (por ejemplo, Random Forest y Gradient Boosting) con métodos explicables para ofrecer análisis cuantitativos fiables y guías interpretativas sobre la influencia de factores académicos, demográficos o socioeconómicos en los patrones de abandono y permanencia (Mustofa et al., 2025).

Estas investigaciones sugieren que, además de observar datos en múltiples puntos temporales, es necesario pensar en cómo se construye el conocimiento a partir de estos datos y cómo los resultados pueden ser útiles para la práctica institucional. El enfoque longitudinal explicable aborda esta necesidad al vincular la evolución del proceso formativo individual con mecanismos interpretativos que facilitan la toma de decisiones pedagógicas informadas, sin perder de vista los desafíos éticos, de equidad y de transparencia que caracterizan a la IA en educación. Este giro conceptual contribuye a ubicar la predicción dentro de un marco de acompañamiento formativo, en el que la tecnología no solo identifica riesgo, sino que ofrece una comprensión más rica y contextualizada del proceso de abandono académico.

ARQUITECTURA CONCEPTUAL DEL MODELO PREDICTIVO LONGITUDINAL

En respuesta a las limitaciones identificadas en los modelos predictivos tradicionales y desde una lógica interdisciplinaria propia del método Introducción-Desarrollo-Conclusiones (IDC), se plantea el diseño de un modelo predictivo longitudinal para la identificación del

riesgo de deserción y bajo rendimiento académico en estudiantes del Tecnológico Nacional de México. La propuesta se fundamenta como una arquitectura analítica modular orientada a integrar medición longitudinal, modelado predictivo explicable y soporte institucional para la toma de decisiones.

En el ámbito de la minería de datos aplicada a la educación superior, investigaciones realizadas recientemente han demostrado que la incorporación de información temporal acumulativa mejora la estabilidad y el desempeño predictivo de los modelos de abandono académico (Rebelo Marcolino et al., 2025).

La arquitectura se organiza en cinco componentes interrelacionados:

- Sistema longitudinal de monitoreo.
- Modelos predictivos explicables.
- Visualización interactiva y alertas tempranas.
- Recomendador institucional de acciones.
- Aplicación adaptable multisitio.

Esta organización responde a una lógica modular que permite integrar la recolección sistemática de datos, el procesamiento analítico y la traducción de los resultados en acciones institucionales.

La propuesta de solución actual es vista desde el método IDC como una síntesis interdisciplinaria que busca integrar aspectos institucionales, psicosociales, analíticos y educativos en un sistema coherente para identificar y abordar los riesgos académicos. La arquitectura propuesta no solo se enfoca en la creación de un modelo predictivo, sino que también combina XAI, mediciones longitudinales y procesos que respaldan la toma de decisiones institucionales. El propósito es potenciar tanto la permanencia como el desempeño académico en educación tecnológica superior.

La Figura 1 detalla la arquitectura del modelo longitudinal explicable. Esta arquitectura posibilita, desde una lógica integradora, la articulación de la recolección sistemática de datos, el análisis predictivo y la intervención académica. Posteriormente, se describen cada una de las etapas de la propuesta de modelo.

Figura 1*Estructura del modelo***SISTEMA LONGITUDINAL DE MONITOREO**

El sistema longitudinal de monitoreo establece la base estructural de la arquitectura propuesta. Este integra la recolección periódica de información que integra datos académicos institucionales con mediciones psicométricas aplicadas en distintos momentos del semestre. A diferencia de modelos que dependen exclusivamente de registros administrativos, esta propuesta contempla la recolección sistemática de información multidimensional orientada a capturar factores asociados al riesgo académico desde una perspectiva integral.

El instrumento en desarrollo incorpora ámbitos personales y demográficos, variables académicas y de responsabilidad estudiantil (como hábitos de estudio, organización del tiempo y cumplimiento de actividades), así como factores psicológicos relacionados con motivación, percepción de autoeficacia y regulación emocional. De manera complementaria, se consideran variables vinculadas a salud y bienestar, condiciones económicas, percepción del entorno institucional y valoración del desempeño docente. Esta integración responde a la premisa de que el abandono y el bajo rendimiento no emergen de un único factor, sino de la interacción progresiva entre múltiples dimensiones que pueden modificarse a lo largo del tiempo.

La aplicación periódica del instrumento permite identificar variaciones intraindividuales y cambios contextuales que no son visibles en registros administrativos estáticos. Este elemento tendría la capacidad de hacer la transición desde una lógica de clasificación puntual a un entendimiento del riesgo académico que esté contextualizado y sea procesual. La medición longitudinal tiene el potencial de ampliar el número de variables analizadas y posibilitar la creación de modelos para trayectorias dinámicas y detectar patrones evolutivos que preceden al abandono o al bajo rendimiento.

Desde una perspectiva longitudinal el seguimiento a estas trayectorias permite identificar hitos críticos, acumulaciones de riesgo y momentos críticos de intervención que permanecen invisibles en los análisis transversales. Inclusive investigaciones recientes han demostrado que la evolución temporal de variables como la motivación y el compromiso académico se asocia significativamente con la persistencia o el abandono estudiantil, reforzando la necesidad de modelos que capturen dichas dinámicas (Eegdeman et al., 2025). Puede sostenerse que el enfoque longitudinal no constituye una decisión solo-técnica, sino también una postura analítica que reconoce el carácter evolutivo del fenómeno educativo.

El sistema longitudinal de monitoreo se configura como la base estructural de la arquitectura propuesta, al proporcionar datos provenientes de factores académicos, personales e institucionales que permiten transitar de una lógica de clasificación puntual hacia una comprensión procesual del riesgo académico.

MODELOS PREDICTIVOS EXPLICABLES

Este componente corresponde al desarrollo de modelos predictivos supervisados orientados a estimar el riesgo de deserción y bajo rendimiento académico a partir de los datos multidimensionales recolectados por el sistema longitudinal de monitoreo. Dado que la proporción de estudiantes que desertan suele ser significativamente menor en comparación con quienes permanecen, el conjunto de datos presenta una distribución asimétrica que requiere estrategias específicas de modelo y de validación, a fin de garantizar estimaciones robustas. y evitar interpretaciones sesgadas.

Se propone el entrenamiento y comparación de distintos modelos de aprendizaje supervisado, incluyendo redes neuronales multicapa (MLP), Random Forest y XGBoost, esto con el propósito de evaluar su capacidad para registrar relaciones no lineales entre las variables multidimensionales recolectadas. La validación del desempeño se realizará mediante esquemas de validación cruzada (*cross-validation*), lo que permitirá estimar la estabilidad y capacidad de generalización del modelo ante distinto subconjunto de datos. De esta manera la evaluación no se limitará a la exactitud global, sino que incorporará métricas sensibles al desbalance, tales como precisión, recall, F1-score y área bajo la curva ROC.

Asimismo, se incorporarán técnicas de explicabilidad como SHAP y LIME para analizar la contribución de cada variable tanto a nivel global como individual. Estas herramientas permitirán la traducción de los resultados técnicos en información perceptible para personal

académico y directivo, fortaleciendo la integración del modelo dentro de procesos institucionales para la toma de decisiones.

La explicabilidad se entiende como un principio estructural que posibilita combinar el análisis algorítmico con la comprensión pedagógica y la toma de decisiones institucionales, en relación con la literatura reciente que la reconoce como un requisito fundamental en sistemas de analítica educativa confiables (Gunasekara & Saarela, 2025).

VISUALIZACIÓN INTERACTIVA Y ALERTAS TEMPRANAS

Este componente se orienta a la traducción operativa de los resultados analíticos en herramientas de apoyo para la toma de decisiones institucionales. Se propone el desarrollo de un panel visual dinámico que permita a directivos y responsables académicos cuando un estudiante se encuentre en riesgo a nivel cohorte, programa y grupo, integrando estimaciones probabilísticas y factores derivados de los mecanismos de explicabilidad que influyen en cada predicción.

Esta propuesta incorpora información interpretativa derivada de los mecanismos de explicabilidad del modelo. Esto va a permitir, no solo detectar niveles de riesgo, sino comprender cuáles son los factores a los que se les están atribuyendo con mayor peso en cada caso. El panel no va a funcionar como una herramienta de clasificación automática, sino como un entorno de análisis contextualizado para el docente o directivo.

Las alertas tempranas que se generan a partir de umbrales adaptativos definidos según el comportamiento longitudinal de las variables permiten anticipar situaciones críticas antes de que se reflejen en indicadores académicos tradicionales. Las recomendaciones asociadas deben entenderse como apoyos para la toma de decisiones y no como determinantes automáticas, manteniendo la intervención final bajo la responsabilidad del personal institucional.

Algunas de las recomendaciones pueden incluir acciones como tutorías académicas, orientación psicoeducativa, contacto con familiares, canalización a servicios de apoyo, ajustes en la carga académica o estrategias de fortalecimiento en hábitos de estudio. Estas sugerencias se deben entender como apoyo para la toma de decisiones y no como determinantes automáticas, siendo la intervención final responsabilidad del personal de la institución.

APLICACIÓN MULTISITIO ADAPTABLE

La propuesta se concibe desde su diseño como un modelo adaptable, capaz de ajustarse a distintos entornos académicos sin perder coherencia metodológica, considerando la diversidad regional del TecNM. Implica variaciones en condiciones socioeconómicas, dinámicas culturales y disponibilidad de recursos institucionales, factores que pueden influir en la configuración del riesgo académico. La adaptabilidad del modelo permita ajustes en los umbrales de riesgo, ponderaciones de variables o criterios de intervención, evitando una aplicación homogénea que ignore particularidades contextuales.

Asimismo, el modelo contempla distintos niveles de madurez institucional permitiendo una implementación gradual adaptada a la infraestructura y las capacidades técnicas de cada campus. Desde este enfoque, la adaptabilidad constituye una condición estructural en el modelo que fortalece la viabilidad y escalabilidad institucional de la propuesta.

CONCLUSIONES

La revisión realizada indica que, aunque los modelos predictivos en la educación superior han logrado niveles cada vez más altos de sofisticación técnica, determinando una brecha entre la optimización algorítmica y la comprensión procesual del abandono y el bajo rendimiento académico. La tendencia a emplear métodos de clasificación binaria del riesgo y a utilizar únicamente datos administrativos puede limitar la posibilidad de captar la complejidad estructural, temporal y contextual de las trayectorias estudiantiles.

Frente a este escenario, la arquitectura conceptual propuesta plantea una estructura analítica longitudinal que integra medición psicométrica periódica, modelado supervisado e XAI dentro de un marco institucional de gobernanza. Más que perfeccionar la capacidad de clasificación, el enfoque busca ampliar el alcance interpretativo de la analítica educativa, incorporando mecanismos de explicabilidad, visualización y acompañamiento académico.

Este planteamiento no pretende sustituir los avances existentes en ciencias de datos educativa, sino más bien orientarlos hacia una lógica procesual en la que la predicción funcione como herramienta de comprensión y soporte para la toma de decisiones. En este sentido, la propuesta enfatiza la importancia de consolidar el rigor metodológico, el seguimiento longitudinal y la transparencia algorítmica como fundamentos para una implementación responsable en contextos de educación tecnológica superior.

Es importante señalar que la arquitectura presentada constituye una propuesta conceptual con potencial de desarrollo empírico posterior. Su implementación efectiva requiere condiciones institucionales específicas, cultura organizacional orientada al uso crítico de datos y marcos claros de supervisión humana. Estas condiciones limitan el alcance del modelo y abren líneas futuras de investigación vinculadas con estudios empíricos, evaluación de impacto y análisis de equidad algorítmica.

En términos conceptuales, el aporte del capítulo radica en proponer un tránsito desde enfoques estáticos de predicción hacia una analítica educativa procesual y explicable, donde la IA funcione como una herramienta de comprensión y soporte para la toma de decisiones, más que un mecanismo de etiquetamiento. De esta manera, la discusión sobre IA en educación superior deja de centrarse únicamente en la precisión de los modelos y pasa a considerar también su impacto pedagógico y su responsabilidad institucional.

REFERENCIAS

- Barus, O. P., Hidayanto, A. N., Handri, E. Y., Sensuse, D. I., & Yaiprasert, C. (2025). Shaping generative AI governance in higher education: Insights from student perception. *International Journal of Educational Research Open*, 8, 100452. <https://doi.org/10.1016/j.ijedro.2025.100452>
- Bean, J. P. (1982). Student attrition, intentions, and confidence: Interaction effects in a path model. *Research in Higher Education*, 17(4), 291–320. <https://doi.org/10.1007/BF00977899>
- Bond, M., Khosravi, H., De Laat, M., Bergdahl, N., Negrea, V., Oxley, E., Pham, P., Chong, S. W., & Siemens, G. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*, 21(1), 4. <https://doi.org/10.1186/s41239-023-00436-z>
- Eegdeman, I., Plak, S., & Meeter, M. (2025). Relating students' motivation trajectories in the first nine weeks of their vocational education program to dropout and persistence. *Motivation and Emotion*, 49(4), 364–383. <https://doi.org/10.1007/s11031-025-10127-z>
- Gunasekara, S., & Saarela, M. (2025). Systematic Literature Review on Explainable Learning Analytics and Educational Data Mining. *IEEE Access*, 13, 214387–214408. <https://doi.org/10.1109/ACCESS.2025.3643645>
- Heffington, D. V., Chulim, F. D., de Lara Hadad, R. F., Morfín, A. P., & Argente, R. A. V. (2024). A Quantitative Approach to Analyzing Student Dropout in Higher Education in Southeastern Mexico. *Revista de la Educacion Superior*, 53(211), 19–40. <https://doi.org/10.36857/resu.2024.211.2954>

- Issah, I., Appiah, O., Appiahene, P., & Inusah, F. (2023). A systematic review of the literature on machine learning application of determining the attributes influencing academic performance. *Decision Analytics Journal*, 7, 100204. <https://doi.org/10.1016/j.dajour.2023.100204>
- Martínez, J., & Castillo, D. (2024). Prediction of student dropout using Artificial Intelligence algorithms. *Procedia Computer Science*, 251, 764–770. <https://doi.org/10.1016/j.procs.2024.11.182>
- Matos, T., Santos, W., Zdravevski, E., Coelho, P. J., Pires, I. M., & Madeira, F. (2025). A systematic review of artificial intelligence applications in education: Emerging trends and challenges. *Decision Analytics Journal*, 15, 100571. <https://doi.org/10.1016/j.dajour.2025.100571>
- Mustofa, S., Emon, Y. R., Mamun, S. B., Akhy, S. A., & Ahad, M. T. (2025). A novel AI-driven model for student dropout risk analysis with explainable AI insights. *Computers and Education: Artificial Intelligence*, 8, 100352. <https://doi.org/10.1016/j.caeai.2024.100352>
- Nti, I. K., & Ramanayake, S. (2025). Explainable Machine Learning for Student Dropout Prediction and Tailored Interventions in Online Personalized Education. En *Review*. <https://doi.org/10.21203/rs.3.rs-6615052/v1>
- Rabelo, A. M., & Zárate, L. E. (2025). A model for predicting dropout of higher education students. *Data Science and Management*, 8(1), 72–85. <https://doi.org/10.1016/j.dsm.2024.07.001>
- Rebelo Marcolino, M., Reis Porto, T., Thompsen Primo, T., Targino, R., Ramos, V., Marques Queiroga, E., Munoz, R., & Cechinel, C. (2025). Student dropout prediction through machine learning optimization: Insights from Moodle log data. *Scientific Reports*, 15(1), 9840. <https://doi.org/10.1038/s41598-025-93918-1>
- Romero, S., & Liao, X. (2025). Statistical and machine learning models for predicting university dropout and scholarship impact. *PLOS One*, 20(6), e0325047. <https://doi.org/10.1371/journal.pone.0325047>
- SEP. (2025). Principales cifras del sistema educativo nacional 2024-2025. https://www.planeacion.sep.gob.mx/Doc/estadistica_e_indicadores/principales_cifras/principales_cifras_2024_2025_bolsillo.pdf
- TecNM. (2024). Tecnológico Nacional de México. (Circular_M00_0023_2024_Abandono Escolar 2024). https://www.tecnm.mx/archivos/circulares/2024/CIRCULAR_M00_0023_2024_ABANDONO_ESCOLAR_Copy_Copy.pdf?pdf=132150
- Tinto, V. (1975). Dropout from Higher Education: A Theoretical Synthesis of Recent Research. *Review of Educational Research*, 45(1), 89–125. <https://doi.org/10.3102/00346543045001089>
- UNESCO. (2022). *Recommendation on the ethics of artificial intelligence*. UNESCO.