

RMPC-Vol.2. N1. 003

Analítica del aprendizaje neuroinclusiva: identificación de sesgos en la evaluación de estudiantes neurodivergentes

Neuroinclusive learning analytics: identifying biases in the assessment of neurodivergent students

Autores:

Giovanni Juan Maldonado Aguirre
Centro de Investigación, Desarrollo e Innovación JOGB
Oruro - Bolivia
<https://orcid.org/0009-0007-8627-8087>
gmaldonadoda@gmail.com

Pamela Navarro Escobar
Centro de Investigación, Desarrollo e Innovación JOGB
Oruro - Bolivia
navarro.docentetutor@gmail.com
<https://orcid.org/0009-0009-4545-9812>

Autor de correspondencia: Giovanni Maldonado Aguirre, <https://orcid.org/0009-0007-8627-8087>

Recepción: 7-01-2025

Aceptación: 26-02-2025

Publicación: 16-03-2025

Cómo citar este artículo:

Maldonado Aguirre, G. J., & Navarro Escobar, P. (2025). Analítica del aprendizaje neuroinclusiva: identificación de sesgos en la evaluación de estudiantes neurodivergentes. Revista Multidisciplinaria Perspectiva Científica, 2(1), 1-19.
<https://rmpc.editorialgutierrez.com/index.php/rmpc/article/view/11>

RESUMEN

La analítica del aprendizaje utiliza datos educativos y modelos computacionales para describir comportamientos, predecir resultados y apoyar decisiones relacionadas con el aprendizaje. Sin embargo, los indicadores utilizados pueden incorporar supuestos sobre formas consideradas típicas de participación, comunicación, atención y rendimiento que no representan adecuadamente la diversidad neurocognitiva. Esta revisión narrativa tuvo como objetivo analizar los riesgos de sesgo asociados con la utilización de analítica del aprendizaje en la evaluación de estudiantes neurodivergentes y determinar principios para una aproximación neuroinclusiva. Se examinó literatura publicada entre 2020 y 2024 relacionada con analítica del aprendizaje, discapacidad, neurodiversidad, equidad algorítmica, evaluación, privacidad y sistemas educativos predictivos. La evidencia muestra que una elevada precisión global no garantiza resultados equitativos entre subgrupos y que las fuentes de datos, políticas de calificación, variables demográficas y definiciones de riesgo pueden modificar las clasificaciones producidas. Para estudiantes neurodivergentes, estos problemas adquieren especial importancia cuando diferencias legítimas de interacción son interpretadas como indicadores de bajo compromiso o riesgo académico. Se concluye que una analítica neuroinclusiva requiere evaluación desagregada de fairness, participación estudiantil, transparencia, protección de datos, validación diferenciada y supervisión humana. La analítica debe utilizarse para identificar barreras y proporcionar apoyos, evitando convertir diferencias neurocognitivas en déficits algorítmicamente contruidos.

Palabras clave: analítica del aprendizaje; neurodiversidad; sesgo algorítmico; evaluación educativa; educación inclusiva.

ABSTRACT

Learning analytics uses educational data and computational models to describe behaviors, predict outcomes, and support learning-related decisions. However, the indicators used may incorporate assumptions about typical forms of participation, communication, attention, and performance that do not adequately represent neurocognitive diversity. This narrative review aimed to analyze the risks of bias associated with the use of learning analytics in the assessment of neurodivergent students and to identify principles for a neuroinclusive approach. Literature published between 2020 and 2024 addressing learning analytics, disability, neurodiversity, algorithmic fairness, assessment, privacy, and predictive educational systems was examined. Evidence indicates that high overall predictive accuracy does not guarantee equitable outcomes across student subgroups and that data sources, grading policies, demographic variables, and definitions of academic risk can substantially affect resulting classifications. For neurodivergent students, these issues become particularly relevant when legitimate differences in interaction are interpreted as indicators of low engagement or academic risk. A neuroinclusive learning analytics approach therefore requires disaggregated fairness assessment, student participation, transparency, data protection, differentiated validation, and meaningful human oversight. Learning analytics should be used to identify barriers and provide appropriate support rather than transforming neurocognitive differences into algorithmically constructed deficits.

Keywords: learning analytics; neurodiversity; algorithmic bias; educational assessment; inclusive education.

1. INTRODUCCIÓN

La analítica del aprendizaje se ha consolidado como un campo orientado a recopilar, analizar e interpretar datos producidos durante las experiencias educativas con el propósito de comprender y mejorar el aprendizaje. Las instituciones pueden utilizar estos datos para identificar estudiantes en riesgo, personalizar apoyos, analizar participación y orientar decisiones académicas. Sin embargo, la creciente incorporación de algoritmos predictivos también ha generado cuestionamientos sobre quién define los indicadores de éxito, qué comportamientos se consideran deseables y qué estudiantes están adecuadamente representados en los datos. Estas preguntas adquieren especial importancia cuando los sistemas intervienen en procesos relacionados con evaluación y clasificación académica (1-4).

La literatura crítica advierte que la analítica del aprendizaje no constituye una tecnología neutral. Los modelos reflejan decisiones acerca de variables, categorías, objetivos, datos de entrenamiento y resultados considerados relevantes. Una predicción técnicamente precisa puede reproducir desigualdades cuando los datos contienen diferencias históricas o cuando el modelo interpreta patrones propios de determinados grupos como desviaciones respecto de una norma mayoritaria (1,4-7). En educación, estas situaciones pueden afectar la identificación de estudiantes en riesgo, la asignación de apoyos y la interpretación de comportamientos digitales, convirtiendo decisiones aparentemente técnicas en mecanismos capaces de amplificar desigualdades preexistentes.

Esta problemática resulta particularmente significativa para estudiantes neurodivergentes. El concepto de neurodiversidad reconoce variaciones en funcionamiento cognitivo, procesamiento sensorial, comunicación, atención y aprendizaje que incluyen, entre otras condiciones, autismo, trastorno por déficit de atención e hiperactividad y dislexia. Desde una perspectiva neuroinclusiva, estas diferencias no deberían interpretarse automáticamente como déficits. Sin embargo, determinados indicadores empleados por sistemas educativos pueden asumir implícitamente patrones neurotípicos de interacción, participación o rendimiento. Cuando estos patrones se convierten en estándares

algorítmicos, estudiantes competentes que aprenden o interactúan de manera diferente pueden aparecer artificialmente como atípicos, poco comprometidos o académicamente vulnerables (8-10).

La evidencia sobre analítica del aprendizaje y discapacidad muestra que la inclusión continúa siendo un componente insuficientemente desarrollado del campo. Las revisiones disponibles señalan que una proporción limitada de investigaciones se centra directamente en estudiantes con discapacidad y que muchas aproximaciones consideran la discapacidad únicamente como variable demográfica secundaria (8,9). Esta situación tiene implicaciones para la neurodivergencia porque la ausencia de representación suficiente limita la capacidad para comprobar si los modelos funcionan de manera equivalente entre diferentes perfiles cognitivos. Un sistema validado únicamente mediante métricas agregadas puede ocultar errores sistemáticos que afectan a grupos minoritarios.

Los sesgos pueden introducirse en diferentes etapas del ciclo analítico. La política utilizada para calificar puede modificar la distribución de los datos y producir una apariencia artificial de elevada precisión al identificar estudiantes en riesgo (3). De manera semejante, investigaciones recientes muestran que las fuentes de datos institucionales pueden contribuir significativamente a diferencias algorítmicas asociadas con edad, género y discapacidad (11). Estos hallazgos demuestran que la precisión global no constituye por sí misma una medida suficiente de calidad. Un modelo puede clasificar correctamente a la mayoría de estudiantes y, simultáneamente, presentar tasas de error desproporcionadas para determinados subgrupos.

La creciente utilización de datos multimodales introduce desafíos adicionales. Registros de navegación, tiempo de interacción, movimientos, voz, ubicación, sensores y otras señales pueden proporcionar información sobre procesos educativos, pero también aumentar riesgos de vigilancia, privacidad e interpretación descontextualizada (12-16). Para estudiantes neurodivergentes, determinados comportamientos digitales o físicos pueden responder a estrategias individuales de autorregulación y no necesariamente a falta de participación. Inferir compromiso, atención o aprendizaje exclusivamente a partir de

patrones normativos podría convertir diferencias conductuales legítimas en indicadores algorítmicos negativos.

En este contexto, resulta necesario avanzar desde una analítica del aprendizaje genéricamente inclusiva hacia una perspectiva específicamente neuroinclusiva. Esta revisión narrativa tiene como objetivo analizar críticamente cómo los datos, métricas y modelos utilizados en analítica del aprendizaje pueden producir sesgos en la evaluación de estudiantes neurodivergentes, identificar las principales fuentes de inequidad y examinar estrategias para desarrollar sistemas más transparentes, justos y sensibles a la diversidad neurocognitiva. El análisis parte del principio de que la finalidad de la analítica educativa debe ser ampliar oportunidades y detectar barreras, evitando convertir diferencias legítimas en déficits mediante procesos automatizados de clasificación (4,7-11).

2. REVISIÓN DE LA LITERATURA

Analítica del aprendizaje y construcción algorítmica del rendimiento

La analítica del aprendizaje transforma actividades educativas en datos susceptibles de clasificación e interpretación. Accesos a plataformas, entregas, calificaciones, participación, secuencias de navegación y otras variables pueden convertirse en indicadores para predecir rendimiento o abandono. Aunque estas técnicas permiten intervenir tempranamente, el significado atribuido a los datos depende de decisiones humanas acerca de qué constituye participación, progreso o riesgo (1,3,4). Por ello, el problema no reside exclusivamente en la exactitud matemática del algoritmo, sino también en las premisas pedagógicas incorporadas al proceso de modelado.

La investigación sobre fairness ha demostrado que modelos con buen desempeño agregado pueden funcionar de manera diferente entre grupos. Bayer et al. cuestionaron explícitamente si los algoritmos existentes sirven por igual a estudiantes pertenecientes a grupos mayoritarios y minoritarios (5). Estudios posteriores han reforzado esta preocupación y mostrado la necesidad de evaluar simultáneamente precisión y equidad (6,7,11). En consecuencia, utilizar únicamente accuracy, AUC o F1 como indicadores de

calidad puede resultar insuficiente cuando una herramienta influye en decisiones educativas que afectan poblaciones heterogéneas.

Neurodiversidad y supuesto de neurotipicidad

Una aproximación neuroinclusiva cuestiona la existencia de un único patrón válido de comportamiento estudiantil. Estudiantes autistas, con TDAH, dislexia u otras formas de neurodivergencia pueden diferir en tiempos de procesamiento, comunicación, regulación atencional, interacción social, organización y utilización de recursos. Estas diferencias pueden influir en los rastros digitales generados durante el aprendizaje sin representar necesariamente menor conocimiento o esfuerzo. Cuando un modelo aprende principalmente de comportamientos neurotípicos, existe el riesgo de convertir esas regularidades mayoritarias en una norma implícita contra la cual se comparan todos los estudiantes.

La limitada presencia de discapacidad en la investigación sobre learning analytics refuerza esta preocupación. Baek y Aguilar encontraron que solo una parte minoritaria de los trabajos recuperados se centraba directamente en estudiantes con discapacidad, mientras Khalil et al. identificaron únicamente 26 estudios relevantes en su revisión sobre inclusión y analítica del aprendizaje (8,9). Esta escasez reduce las posibilidades de conocer cómo funcionan los modelos para subgrupos específicos y dificulta distinguir entre diferencias asociadas con barreras del entorno y verdaderas señales de dificultades académicas.

Sesgo en predicción y clasificación de riesgo

La identificación temprana de estudiantes en riesgo constituye una de las aplicaciones más frecuentes de la analítica. Sin embargo, la categoría “en riesgo” depende de la variable utilizada para definir éxito o fracaso. Lu et al. demostraron que las políticas docentes de calificación pueden generar desequilibrios en los datos y producir una ilusión de elevada precisión predictiva (3). Esto implica que el algoritmo puede aprender parcialmente las características de un sistema de evaluación en lugar de identificar exclusivamente patrones asociados con aprendizaje.

Idowu et al. analizaron específicamente sesgos asociados con edad, género y discapacidad utilizando datos de Open University. Los resultados mostraron que los datos institucionales constituían la fuente con mayor contribución al sesgo, seguidos por los registros del entorno virtual, mientras que los datos de evaluación presentaban menor sesgo relativo (11). Además, demostraron que estrategias de mitigación podían mejorar fairness sin necesariamente sacrificar precisión. Estos hallazgos son especialmente relevantes para una analítica neuroinclusiva porque indican que el origen del sesgo puede encontrarse antes del algoritmo, dentro de los propios datos utilizados para representar al estudiante.

Fairness, equidad y responsabilidad

Fairness no posee una única definición matemática. Diferentes métricas pueden evaluar paridad de resultados, igualdad de oportunidades o diferencias en tasas de error, y optimizar una dimensión puede entrar en tensión con otra (6,7). Por ello, la selección de una métrica constituye también una decisión normativa. En contextos neuroinclusivos, esta cuestión obliga a determinar qué significa realmente tratar justamente a estudiantes que pueden necesitar diferentes condiciones para demostrar la misma competencia.

La literatura propone complementar las métricas computacionales con transparencia, responsabilidad institucional y participación de las personas afectadas (17-20). Una herramienta puede cumplir determinado umbral estadístico y continuar siendo problemática si sus categorías no representan adecuadamente las experiencias estudiantiles. La justicia algorítmica educativa requiere, por tanto, considerar tanto la distribución matemática de errores como las consecuencias pedagógicas de esos errores.

Privacidad, datos sensibles y neurodivergencia

La analítica requiere grandes cantidades de información y puede incorporar datos particularmente sensibles. Los estudiantes han manifestado preocupaciones respecto de conocimiento institucional, consentimiento, control y utilización de sus datos (13,14,21). La desidentificación tampoco garantiza protección completa, porque diferentes conjuntos de datos pueden combinarse y permitir inferencias sobre individuos (22).

Para estudiantes neurodivergentes esta dimensión adquiere especial relevancia. La condición puede no estar diagnosticada o el estudiante puede decidir no revelarla. Construir modelos neuroinclusivos no significa exigir información diagnóstica adicional, porque ello podría aumentar vigilancia y estigmatización. El desafío consiste en desarrollar sistemas capaces de tolerar diversidad de comportamientos sin necesitar convertir toda diferencia en una categoría clínica.

Analítica multimodal y riesgo de interpretación normativa

La analítica multimodal amplía las fuentes de información mediante voz, posición, movimiento, sensores y otras señales. Aunque estas tecnologías permiten estudiar procesos complejos, también incrementan el riesgo de vigilancia y pérdida de privacidad (12). Inferir atención o compromiso mediante contacto visual, inmovilidad, participación verbal u otros indicadores puede ser especialmente problemático para estudiantes neurodivergentes.

Una perspectiva neuroinclusiva debería cuestionar la equivalencia entre comportamiento observable y aprendizaje. El estudiante que no reproduce el patrón conductual esperado puede comprender perfectamente la actividad. Por ello, los datos multimodales necesitan interpretación contextual, consentimiento y validación con poblaciones diversas antes de utilizarse en evaluación o decisiones de alto impacto.

3. METODOLOGÍA

Diseño

Se realizó una revisión narrativa orientada a integrar evidencia sobre analítica del aprendizaje, sesgo algorítmico, discapacidad, neurodiversidad, evaluación, fairness y privacidad educativa. Se eligió este enfoque debido al carácter interdisciplinario y todavía emergente de la analítica neuroinclusiva, que requiere relacionar literatura directamente centrada en estudiantes neurodivergentes con investigaciones sobre grupos con discapacidad y estudios generales de equidad algorítmica aplicables al problema analizado.

Periodo y fuentes

La búsqueda se delimitó al periodo 2020-2024. Se priorizaron artículos científicos y trabajos académicos verificables mediante DOI o URL editorial relacionados con learning analytics, neurodiversity, disability, algorithmic bias, fairness, educational assessment, at-risk students, privacy, inclusive education y términos relacionados. Se utilizaron combinaciones booleanas destinadas a conectar analítica educativa con diversidad, discapacidad, sesgo y evaluación.

Criterios de inclusión

Se incluyeron estudios que abordaran al menos uno de los siguientes componentes: analítica del aprendizaje y estudiantes con discapacidad; equidad o fairness en modelos educativos; sesgos en predicción de rendimiento; evaluación automatizada; privacidad y gobernanza de datos; analítica multimodal; o implicaciones para poblaciones vulnerables. Se priorizaron investigaciones con metodología y resultados identificables y revisiones que permitieran establecer el estado del conocimiento.

Criterios de exclusión

Se excluyeron documentos sin trazabilidad bibliográfica suficiente, publicaciones anteriores al periodo establecido salvo antecedentes conceptuales imprescindibles y estudios cuya relación con educación o analítica fuera incidental. También se evitó considerar automáticamente como evidencia sobre neurodivergencia cualquier investigación referida genéricamente a discapacidad.

Estrategia de análisis

La evidencia se organizó mediante síntesis temática alrededor de cinco dimensiones: representación de estudiantes neurodivergentes; fuentes de sesgo; fairness de modelos predictivos; privacidad y gobernanza; y principios para analítica neuroinclusiva. No se realizó metaanálisis debido a la heterogeneidad de diseños, poblaciones, variables y métricas.

4. RESULTADOS

El análisis mostró una brecha entre el rápido desarrollo técnico de la analítica del aprendizaje y la incorporación explícita de diversidad neurológica en sus modelos. Las investigaciones directamente centradas en discapacidad continúan siendo minoritarias (8,9), mientras que los estudios sobre fairness demuestran que características protegidas y fuentes de datos pueden producir diferencias significativas en el desempeño de los algoritmos (5-7,11).

Representación y riesgo de invisibilidad

La primera tendencia identificada fue la insuficiente representación de estudiantes con discapacidad y, de manera todavía más marcada, de perfiles neurodivergentes específicos. Esta ausencia dificulta evaluar sensibilidad, especificidad y tasas de falsos positivos o negativos dentro de poblaciones como estudiantes autistas, con TDAH o dislexia. La falta de datos no significa ausencia de sesgo; puede impedir precisamente que dicho sesgo sea detectado.

Tabla 1. Fuentes de sesgo relevantes para una analítica del aprendizaje neuroinclusiva

Fuente	Mecanismo	Riesgo para estudiantes neurodivergentes	Control necesario
Datos históricos	Reproducen desigualdades previas	Normalización de patrones mayoritarios	Auditoría de representatividad
Actividad VLE	Equipara interacción con compromiso	Interpretación errónea de ritmos diferentes	Validación por subgrupos
Calificaciones	Dependen de políticas docentes	Riesgo académico construido por la evaluación	Analizar efecto de grading
Datos institucionales	Incluyen variables demográficas	Discriminación indirecta	Fairness desagregado
Datos multimodales	Infieren estados desde conducta	Neurotipicidad convertida en norma	Validación neurodiversa

Fuente	Mecanismo	Riesgo para estudiantes neurodivergentes	Control necesario
Diagnóstico	Categoriza diferencias cognitivas	Estigmatización o profiling	Minimización de datos

Precisión no equivalente a equidad

La segunda tendencia fue la insuficiencia de la precisión global como criterio único. Los modelos pueden alcanzar buenos resultados generales mientras distribuyen errores de manera desigual. Bayer et al. mostraron diferencias en funcionamiento entre grupos mayoritarios y minoritarios (5), mientras investigaciones sobre fairness señalan la necesidad de utilizar métricas específicas para detectar estas desigualdades (6,7).

El estudio de Idowu et al. proporciona evidencia particularmente importante porque analizó explícitamente discapacidad junto con edad y género. Encontró que las fuentes institucionales eran las que más contribuían a la discriminación y que procedimientos de mitigación podían reducir sesgo sin deteriorar necesariamente la precisión (11). Esto demuestra que la fairness debe evaluarse durante todo el ciclo analítico.

Tabla 2. Evidencias clave y aportación al problema neuroinclusivo

Estudio	Evidencia	Resultado relevante	Implicación neuroinclusiva
Lu et al. (3)	12 cursos blended	La política de calificación puede crear ilusión de alta precisión	La evaluación previa condiciona el modelo
Bayer et al. (5)	Modelos predictivos	Diferencias entre grupos mayoritarios/minoritarios	Validar desempeño por subgrupo
Baek y Aguilar (8)	Revisión	Baja proporción de investigación centrada en discapacidad	Déficit de representación

Estudio	Evidencia	Resultado relevante	Implicación neuroinclusiva
Khalil et al. (9)	26 estudios	Potencial inclusivo pero vacíos importantes	Inclusión todavía emergente
Idowu et al. (11)	OULAD	Sesgo por edad, discapacidad y género	Auditar fuentes antes del modelado
Prinsloo et al. (12)	192 trabajos MMLA	Riesgos de privacidad y vigilancia	Limitar inferencias conductuales

Evaluación y clasificación de riesgo

Los resultados indican que una etiqueta de riesgo no constituye una propiedad natural del estudiante. Se construye mediante criterios de rendimiento, calificación, participación y comportamiento. Cuando estos criterios reflejan patrones neurotípicos, las diferencias neurocognitivas pueden convertirse en señales de riesgo aunque el estudiante alcance los resultados de aprendizaje.

Esto resulta especialmente problemático en sistemas de alerta temprana. Un falso positivo puede producir intervenciones innecesarias, estigmatización o expectativas académicas reducidas; un falso negativo puede impedir que un estudiante reciba apoyo. Por ello, la evaluación de fairness debería considerar no solo cuántos errores produce el modelo, sino sobre quién recaen y cuáles son sus consecuencias.

Privacidad y agencia

Los estudios sobre privacidad muestran que los estudiantes desean mayor conocimiento y control sobre el uso de sus datos (13,14,21). Para neurodivergencia, la protección debe extenderse a inferencias algorítmicas: un sistema podría inferir patrones sensibles aun cuando el estudiante nunca haya comunicado un diagnóstico.

Tabla 3. Marco propuesto para auditoría neuroinclusiva de learning analytics

Dimensión	Pregunta de auditoría	Indicador de riesgo	Salvaguarda
Representación	¿Están incluidos perfiles diversos?	Subgrupos ausentes	Evaluación de representatividad
Validez	¿La variable mide aprendizaje o comportamiento típico?	Proxy conductual débil	Validación pedagógica
Fairness	¿Los errores son equivalentes entre grupos?	FPR/FNR desiguales	Métricas desagregadas
Evaluación	¿La calificación introduce sesgo?	Data imbalance	Análisis de política de grading
Privacidad	¿Se infieren datos sensibles?	Profiling no consentido	Minimización de datos
Transparencia	¿Puede explicarse la clasificación?	Caja negra	Explicabilidad significativa
Intervención	¿La predicción apoya o sanciona?	Consecuencia punitiva	Human-in-the-loop
Participación	¿Intervinieron estudiantes neurodivergentes?	Diseño exclusivamente técnico	Codiseño neuroinclusivo

Los resultados convergen en una conclusión central: una analítica neuroinclusiva no consiste en crear modelos separados para cada diagnóstico, sino en diseñar sistemas capaces de reconocer diversidad, comprobar desigualdades y evitar que un único patrón de comportamiento se transforme en norma universal.

5. DISCUSIÓN

Los hallazgos muestran que la principal amenaza para estudiantes neurodivergentes no procede necesariamente de un algoritmo explícitamente discriminatorio, sino de la normalización silenciosa de determinados comportamientos. Cuando frecuencia de acceso, velocidad de respuesta, participación verbal, regularidad temporal o interacción social se utilizan como proxies de aprendizaje, las diferencias neurocognitivas pueden adquirir significado negativo sin fundamento pedagógico suficiente (1,4,8,9).

Esta interpretación permite comprender por qué la precisión global resulta insuficiente. Si los estudiantes neurodivergentes representan una proporción minoritaria del conjunto de datos, un modelo puede alcanzar una elevada accuracy incluso clasificándolos sistemáticamente peor. Los trabajos sobre fairness confirman la necesidad de evaluar el rendimiento desagregado y analizar tasas de error entre grupos (5-7,11).

Los resultados de Idowu et al. son particularmente relevantes porque demuestran empíricamente que la discapacidad puede asociarse con disparidades algorítmicas y que el origen del problema varía según la fuente de datos (11). La observación de que los datos institucionales aportaron mayor sesgo que los datos de evaluación cuestiona la idea de que incorporar más información produce necesariamente mejores decisiones.

La política de evaluación constituye otra fuente crítica. Lu et al. demostraron que estrategias de calificación pueden alterar la identificación de estudiantes en riesgo y generar una apariencia engañosa de precisión (3). Para estudiantes neurodivergentes, esto implica una posible acumulación de sesgos: una evaluación originalmente poco inclusiva produce resultados desiguales y esos resultados posteriormente entrenan un modelo que aprende a reproducirlos.

La analítica multimodal intensifica el problema porque transforma características conductuales en datos. Los riesgos de privacidad identificados en la revisión de Prinsloo et al. adquieren una dimensión adicional cuando señales como voz, movimiento o interacción se utilizan para inferir atención o compromiso (12). La neurodiversidad obliga a cuestionar esas inferencias porque no existe una única manifestación conductual válida del aprendizaje.

La respuesta tampoco consiste simplemente en incorporar el diagnóstico como atributo protegido. Aunque esta información permitiría medir ciertas desigualdades, exigirla puede producir riesgos de privacidad y discriminación. Muchos estudiantes pueden no disponer de diagnóstico, no identificarse mediante una categoría clínica o preferir no comunicarla. Una analítica verdaderamente neuroinclusiva debe funcionar razonablemente bien incluso ante neurodivergencia no declarada.

Los estudios sobre privacidad y confianza refuerzan la necesidad de participación estudiantil (13,14,21,22). La transparencia no debería limitarse a informar que los datos serán utilizados. Los estudiantes necesitan conocer qué datos influyen en las predicciones, qué consecuencias pueden derivarse y cómo cuestionar una clasificación. Esta posibilidad de contestación resulta esencial cuando una decisión algorítmica puede afectar apoyos, evaluación o trayectoria académica.

La evidencia revisada permite proponer un cambio conceptual: pasar de una analítica orientada a detectar estudiantes “anormales” a una analítica destinada a detectar barreras y desajustes entre estudiante y entorno. Bajo esta perspectiva, un patrón atípico no constituye automáticamente una deficiencia. Se convierte en una señal que requiere contextualización antes de intervenir.

6. CONCLUSIONES

La analítica del aprendizaje ofrece posibilidades relevantes para comprender procesos educativos, identificar necesidades y proporcionar apoyos personalizados, pero sus beneficios no se distribuyen automáticamente de manera equitativa. Los modelos se construyen sobre datos, categorías y supuestos que pueden reflejar patrones mayoritarios de aprendizaje y comportamiento. Para estudiantes neurodivergentes, esta situación crea el riesgo de que diferencias legítimas sean interpretadas como falta de compromiso, bajo rendimiento o vulnerabilidad académica.

La evidencia analizada demuestra que la precisión global no garantiza fairness. Diferentes fuentes de datos, políticas de calificación y atributos estudiantiles pueden modificar la distribución de errores y generar clasificaciones desiguales. Por ello, cualquier sistema utilizado en evaluación o identificación de riesgo debería incorporar análisis desagregados y procedimientos explícitos para detectar y mitigar sesgos.

Una analítica neuroinclusiva no debe depender exclusivamente de diagnósticos. La diversidad neurológica incluye estudiantes diagnosticados, no diagnosticados y personas que deciden no revelar información sensible. Los sistemas deberían diseñarse para tolerar

diferentes patrones de interacción sin convertir automáticamente la desviación respecto de una norma estadística en señal negativa.

La protección de privacidad, transparencia, explicabilidad y participación estudiantil constituyen componentes inseparables de la fairness. Los estudiantes neurodivergentes deben participar en el diseño y evaluación de herramientas que puedan influir sobre sus experiencias académicas. La supervisión humana debe conservarse especialmente cuando una predicción pueda producir consecuencias educativas relevantes.

Finalmente, la analítica neuroinclusiva requiere modificar la pregunta fundamental. En lugar de preguntar únicamente qué estudiante se desvía del comportamiento esperado, los sistemas deberían ayudar a determinar qué barrera del entorno impide que diferentes estudiantes demuestren adecuadamente su aprendizaje. Este cambio desplaza el foco desde el déficit individual hacia la responsabilidad del sistema educativo y permite utilizar la analítica como instrumento de inclusión y no como mecanismo de normalización neurotípica.

REFERENCIAS BIBLIOGRÁFICAS

1. Selwyn N. Re-imagining 'Learning Analytics' ... a case for starting again? Internet High Educ. 2020;46:100745. <https://doi.org/10.1016/j.iheduc.2020.100745>
2. Smith H. Algorithmic bias: should students pay the price? AI Soc. 2020;35(4):1077-1078. <https://doi.org/10.1007/s00146-020-01054-3>
3. Lu OHT, Huang AYQ, Yang SJH. Impact of teachers' grading policy on the identification of at-risk students in learning analytics. Comput Educ. 2021;163:104109. <https://doi.org/10.1016/j.compedu.2020.104109>.
4. Baker RS, Hawn A. Algorithmic bias in education. Int J Artif Intell Educ. 2022;32:1052-1092. <https://doi.org/10.1007/s40593-021-00285-9>.
5. Bayer V, Hlostá M, Fernández M. Learning analytics and fairness: do existing algorithms serve everyone equally? In: Artificial Intelligence in Education. Cham: Springer; 2021. p.71-75. https://doi.org/10.1007/978-3-030-78270-2_12

6. Deho OB, Zhan C, Li J, Liu J. How do the existing fairness metrics and unfairness mitigation algorithms contribute to ethical learning analytics? *Br J Educ Technol*. 2022;53. <https://doi.org/10.1111/bjet.13217>
7. Sahlgren O. The politics and reciprocal (re)configuration of accountability and fairness in data-driven education. *Learn Media Technol*. 2022. <https://doi.org/10.1080/17439884.2021.1986065>
8. Baek C, Aguilar SJ. Past, present, and future directions of learning analytics research for students with disabilities. *J Res Technol Educ*. 2023;55(6):931-946. <https://doi.org/10.1080/15391523.2022.2067796>.
9. Khalil M, Slade S, Prinsloo P. Learning analytics in support of inclusiveness and disabled students: a systematic review. *J Comput High Educ*. 2024;36:202-219. <https://doi.org/10.1007/s12528-023-09363-4>.
10. Khalil M, Prinsloo P, Slade S. The use and application of learning theory in learning analytics: a scoping review. *J Comput High Educ*. 2023;35:573-594. <https://doi.org/10.1007/s12528-022-09340-3>.
11. Idowu JA, Koshiyama AS, Treleaven P. Investigating algorithmic bias in student progress monitoring. *Comput Educ Artif Intell*. 2024;7:100267. <https://doi.org/10.1016/j.caeai.2024.100267>.
12. Prinsloo P, Slade S, Khalil M. Multimodal learning analytics—in-between student privacy and encroachment: a systematic review. *Br J Educ Technol*. 2023;54:1566-1586. <https://doi.org/10.1111/bjet.13373>.
13. Jones KML, Asher A, Goban A, et al. “We’re being tracked at all times”: student perspectives of their privacy in relation to learning analytics in higher education. *J Assoc Inf Sci Technol*. 2020;71:1044-1059. <https://doi.org/10.1002/asi.24358>.
14. Mutimukwe C, Viberg O, Oberg LM, Cerratto-Pargman T. Students’ privacy concerns in learning analytics: model development. *Br J Educ Technol*. 2022;53:932-951. <https://doi.org/10.1111/bjet.13234>.
15. Prinsloo P, Slade S, Khalil M. The answer is (not only) technological: considering student data privacy in learning analytics. *Br J Educ Technol*. 2022;53:876-893. <https://doi.org/10.1111/bjet.13216>.

16. Yacobson E, Fuhrman O, Hershkovitz S, Alexandron G. De-identification is insufficient to protect student privacy, or—what can a field trip reveal? *J Learn Anal.* 2021. <https://doi.org/10.18608/jla.2021.7353>
17. Heiser R, Dello Stritto ME, Brown A, Croft B. Amplifying student and administrator perspectives on equity and bias in learning analytics. *J Learn Anal.* 2023;10(1):8-23. <https://doi.org/10.18608/jla.2023.7775>.
18. Khalil M, Prinsloo P, Slade S. Fairness, trust, transparency, equity, and responsibility in learning analytics. *J Learn Anal.* 2023;10(1):1-7. <https://doi.org/10.18608/jla.2023.7983>.
19. Jin Y, Echeverria V, Yan L, et al. FATE in MMLA: a student-centred exploration of fairness, accountability, transparency, and ethics in multimodal learning analytics. *J Learn Anal.* 2024;11(3):6-23. <https://doi.org/10.18608/jla.2024.8351>.
20. Froehlich L, Weydner-Volkman S. Adaptive interventions reducing social identity threat to increase equity in higher distance education: a use case and ethical considerations on algorithmic fairness. *J Learn Anal.* 2024. <https://doi.org/10.18608/jla.2024.8301>
21. Jones KML, Rubel A, LeClere E. A matter of trust: higher education institutions as information fiduciaries in an age of educational data mining and learning analytics. *J Assoc Inf Sci Technol.* 2020;71:1227-1241. <https://doi.org/10.1002/asi.24327>.
22. Chang B. Student privacy issues in online learning environments. *Distance Educ.* 2021;42(1):55-69. <https://doi.org/10.1080/01587919.2020.1869527>.
23. Prinsloo P, Khalil M, Slade S. Vulnerable student digital well-being in AI-powered educational decision support systems (AI-EDSS) in higher education. *Br J Educ Technol.* 2024;55:2075-2092. <https://doi.org/10.1111/bjet.13508>.
24. Conde MA, Rodríguez-Sedano FJ. Is learning analytics applicable and applied to education of students with intellectual/developmental disabilities? A systematic literature review. *Comput Hum Behav.* 2024;155:108184. <https://doi.org/10.1016/j.chb.2024.108184>.
25. Opoku RA, Pei B, Xing W. Unveiling accuracy-fairness trade-offs: investigating machine learning models in student performance prediction. *J Learn Anal.* 2024. <https://doi.org/10.18608/jla.2024.8543>

CONFLICTO DE INTERESES

Los autores afirman que no existen conflictos de intereses en este estudio y que se han seguido éticamente los procesos establecidos por esta revista. Además, aseguran que este trabajo no ha sido publicado parcial ni totalmente en ninguna otra revista.

FINANCIAMIENTO

Los autores no recibieron financiamiento para el desarrollo de esta investigación.

CONTRIBUCIÓN DE AUTORÍA

Autores e iniciales: Giovanni Juan Maldonado Aguirre y Pamela Navarro Escobar

Planteamiento de la idea: GJMA

Estructuración metodológica: PNE

Levantamiento y gestión de información: GJMA

Sistematización de datos: GJMA y PNE

Procesamiento e interpretación de resultados: GJMA

Verificación de la información: GJMA

Elaboración de recursos visuales: PNE

Coordinación del estudio: PNE

Redacción inicial del manuscrito: PNE y GJMA

Corrección académica y edición final: GJMA y PNE

Todos los autores revisaron y aprobaron la versión final del manuscrito.

© 2025; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (<https://creativecommons.org/licenses/by/4.0>) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.