

Artículo original

Transfer learning e inteligencia artificial: potenciando el aprendizaje y servicio



Transfer learning and artificial intelligence: boosting learning and service

Transfer learning e inteligência artificial: potenciando a aprendizagem e o serviço

Mario Gabriel Sarián González¹  0000-0003-2271-0532  msarian@unap.cl

Lourdes Marlene Yaque Rueda²  0000-0003-6025-3016  yaqlourd@ucvvirtual.edu.pe

Ysrael Alberto Martínez Contreras³  0000-0003-0865-057X  ymartinezc@autonoma.edu.pe

¹ Universidad Arturo Prat. Chile.

² Universidad César Vallejo. Perú.

³ Universidad Autónoma del Perú. Perú.

Recibido: 12/08/2025

Aceptado: 24/04/2026

RESUMEN

La vinculación con el medio requiere de la metodología del aprendizaje servicio y el modelo del Transfer Learning en cumplimiento de los propósitos epistemológico y ontológico en la universidad. El objetivo de la investigación es proponer la utilización del Transfer Learning y la metodología del Aprendizaje-Servicio para el uso educativo en educación superior. La metodología utilizada es Bidirectional Encoder Representations from Transformers la cual es un modelo entrenado en función a la personalización del aprendizaje en estudiantes. Además, se enfatizó la Función de Pérdida, Optimización por Descenso de Gradiente, la Regularización y la evolución del modelo basado en métricas Precisión o Accuracy, F1-Score y Recall y Precision. Los potenciales resultados se proyectan

en el Aprendizaje-Servicio al ser enriquecido con la Inteligencia Artificial, incentivando a los estudiantes a involucrarse en proyectos comunitarios, lo que fortalece tanto su aprendizaje académico como sus habilidades sociales. Además, se destaca cómo el Transfer Learning puede hacer más efectivas las evaluaciones, personalizando las recomendaciones según el progreso de cada estudiante. En conclusión, la combinación de Transfer Learning sostenida en Inteligencia Artificial y apoyada en Aprendizaje-Servicio tiene la capacidad de sostener la transformación de la educación, haciéndola más accesible, inclusiva y centrada en las necesidades del estudiante, mejorando las evaluaciones y promoviendo una pedagogía más innovadora.

Palabras clave: educación superior; gestión del conocimiento; habilidades digitales; recursos digitales.

ABSTRACT

Engagement with the community requires the service-learning methodology and the transfer learning model to fulfill the epistemological and ontological objectives of the university. The objective of this research is to propose the use of transfer learning and the service-learning methodology in higher education. The methodology used is Bidirectional Encoder Representations from Transformers, which is a model trained to personalize student learning. Additionally, emphasis is placed on the loss function, gradient descent optimization, regularization, and model evolution based on metrics such as accuracy, F1-score, recall, and precision. The potential outcomes are projected into Service-Learning, which is enriched by Artificial Intelligence, encouraging students to engage in community projects, thereby strengthening both their academic learning and their social skills. Furthermore, the paper highlights how Transfer Learning can make assessments more effective by personalizing recommendations based on each student's progress. In conclusion, the combination of Transfer Learning grounded in Artificial Intelligence and supported by Service-Learning has the potential to drive the transformation of education, making it more accessible, inclusive, and student-centered, while improving assessments and promoting more innovative pedagogy.

Keywords: higher education; knowledge management; digital skills; digital resources.

RESUMO

A integração com o meio social requer a metodologia da aprendizagem em serviço e o modelo de Transfer Learning, em conformidade com os objetivos epistemológicos e ontológicos da universidade. O objetivo da pesquisa é propor a utilização do Transfer Learning e da metodologia da Aprendizagem em Serviço no contexto educacional do ensino superior. A metodologia utilizada é a Bidirectional Encoder Representations from Transformers, que é um modelo treinado com base na personalização da aprendizagem dos alunos. Além disso, enfatizou-se a Função de Perda, a Otimização por Gradiente Descendente, a Regularização e a evolução do modelo com base nas métricas Precisão ou Accuracy, F1-Score e Recall e Precision. Os resultados potenciais se projetam na Aprendizagem-Serviço ao ser enriquecida com Inteligência Artificial, incentivando os alunos a se envolverem em projetos comunitários, o que fortalece tanto sua aprendizagem acadêmica quanto suas habilidades sociais. Além disso, destaca-se como o Aprendizado por Transferência pode tornar as avaliações mais eficazes, personalizando as recomendações de acordo com o progresso de cada aluno. Em conclusão, a combinação do Aprendizado por Transferência, sustentada pela Inteligência Artificial e apoiada na Aprendizagem-Serviço, tem a capacidade de sustentar a transformação da educação, tornando-a mais acessível, inclusiva e centrada nas necessidades do aluno, melhorando as avaliações e promovendo uma pedagogia mais inovadora.

Palavras-chave: ensino superior; gestão do conhecimento; competências digitais; recursos digitais.

INTRODUCCIÓN

Desde la experiencia, se constata que el Aprendizaje-Servicio (ApS) vincula los saberes teóricos con la práctica social con la creación de habilidades blandas las cuales son necesarias en los entornos educativos emergentes. En escenarios postpandemia, el desafío es integrar herramientas tecnológicas como el Transfer Learning (TL) en los procesos pedagógicos con sentido social. El Aprendizaje-Servicio (ApS) se fundamenta en la idea donde el conocimiento académico, se vincula al desarrollo de habilidades sociales y éticas (Drewery & Lollar, 2024; Shea et al., 2022). Mediante la participación en proyectos que impactan positivamente a la comunidad, los estudiantes adquieren una formación integral. La metodología ApS tiene especial relevancia en momentos de crisis, como lo vivimos durante la pandemia de COVID-19, cuando la educación presencial fue reemplazada por modalidades digitales. Aunque permitió acceso amplio a la educación trajo consigo oportunidades y

dificultades relacionadas con la calidad y la equidad del aprendizaje. La integración del modelo Transfer Learning (TL) ha sido importante en contexto al inducir la adaptación de modelos de sistemas inteligentes en diversos conceptos y optimizar el aprendizaje de los estudiantes en forma individual e independiente del entorno. La combinación de ApS y TL facilita un proceso de aprendizaje continuo, flexible y autónomo al promover la innovación, servicio y el pensamiento crítico. La implementación de tecnologías avanzadas potencia la educación mientras en simultáneo se prepara a los alumnos para afrontar las oportunidades, desarrollando competencias profesionales esenciales en la sociedad actual (Arteaga-Tuba, 2024; Castro & Gómez, 2022).

El ApS es una metodología formulada desde el aprendizaje de la especialidad hacia su implementación ante sujetos de estudios (Pinto & Costa-Ramalho, 2023; Tarazona et al., 2024) sincrónicos o asincrónicos de tal forma de cumplir con el perfil del egresado de cada estudiante quien implemente dicha propuesta. La metodología requiere participación de cada estudiante y docente quienes intervienen en forma presencial o semi presencial o a distancia según las características del lugar de intervención. Se inicia en trabajo de gabinete para luego desplazar el esfuerzo hacia las zonas de intervención sea sincrónico o asincrónico.

El aprendizaje por TL es un modelo dentro del campo del machine learning debido a su capacidad en reutilizar modelos preentrenados y aplicarlos en tareas relacionadas, reduciendo significativamente la necesidad de datos específicos en cada nueva tarea. El enfoque mejora el rendimiento del modelo en situaciones donde los datos son limitados, como en el ámbito educativo o sanitario (Lauriola et al., 2022).

En los diseños tradicionales de machine learning, es necesario entrenar los algoritmos desde cero, lo que exige una gran cantidad de números de comportamiento y tiempo en alcanzar un rendimiento eficiente. Sin embargo, el aprendizaje por TL aprovecha el conocimiento adquirido previamente en tareas similares, adaptando modelos preentrenados a nuevas aplicaciones con una mínima cantidad de datos adicionales (Taye, 2023).

El TL ha sido particularmente eficaz en el campo del procesamiento del lenguaje natural (NLP), donde se emplean modelos como BERT (Bidirectional Encoder Representations from Transformers), preentrenados en grandes conjuntos de datos textuales, para realizar trabajos específicos como la selección de contenido o el análisis de sentimiento. El enfoque ha demostrado que transferir características aprendidas en tareas generales a problemas específicos reduce la necesidad de

entrenar desde cero y mejora la precisión y el tiempo de respuesta de los modelos (Lauriola et al., 2022).

Uno de los campos beneficiados de esta técnica es la educación, donde los modelos preentrenados personalizan la enseñanza y la evaluación de los estudiantes. Los modelos permiten a los sistemas de inteligencia artificial analizar las interacciones de los estudiantes con el contenido educativo y las respuestas a evaluaciones, proporcionando retroalimentación personalizada que identifica las áreas de mejora y sugiere estrategias en el progreso académico (Castillejos, 2022). Según Castro & Gómez (2022), el uso de TL en plataformas educativas ha demostrado que es posible ajustar los modelos de identificación de patrones de aprendizaje en diferentes grupos de estudiantes y aplicar dicho conocimiento a contextos educativos específicos.

Además de la personalización de la educación, el TL facilita la implementación de soluciones de IA en instituciones educativas con menor disponibilidad de recursos, ya que los modelos preentrenados se adaptan rápidamente a los entornos locales sin la necesidad de recopilar grandes cantidades de datos. Como resultado, las instituciones optimizan la enseñanza, la retroalimentación y la evaluación, ajustándose a las necesidades de cada estudiante en favor de la equidad y eficiencia educativa (Pinto & Costa-Ramvalho, 2023; Hernández, 2025; Taye, 2023). El enfoque basado en Transfer Learning e inteligencia artificial analiza los datos de los estudiantes, se adapta a sus necesidades y mejora la experiencia educativa a través de retroalimentación y recomendaciones personalizadas (Taye, 2023).

El aprendizaje por TL ha revolucionado el campo del machine learning al permitir que los modelos preentrenados se adapten a nuevas tareas con un costo reducido en términos de datos y tiempo. En el ámbito educativo, esta técnica no solo optimiza los procesos de evaluación, sino que personaliza la enseñanza y mejora los resultados académicos, representando un avance significativo en la educación basada en inteligencia artificial.

MATERIALES Y MÉTODOS

Se usó una computadora y PSeInt (acrónimo de PSeudo Intérprete) es una herramienta educativa diseñada en soporte de aprendizaje lógico de programación y algoritmos, sin necesidad de saber un lenguaje de programación específico desde el comienzo. PSeInt está diseñado con un motor de interpretación propio, desarrollado en lenguaje C++ el cual simula el flujo lógico de algoritmos escritos en pseudocódigo estructurado. Este motor no actúa como un compilador o intérprete

tradicional, sino como una herramienta educativa la cual reproduce paso a paso la ejecución lógica del algoritmo, con el objetivo de ayudar en el entendimiento de la programación y el razonamiento computacional.

Descripción del Método Lógico

El enfoque se contextualiza en una práctica real aplicada en una asignatura de formación docente, donde se adaptan los algoritmos de clasificación textual a las respuestas de estudiantes en actividades reflexivas. El análisis no solo se centró en la precisión técnica del modelo, sino en cómo estas herramientas se integran con sentido pedagógico en aulas.

El método y comprobación utilizan el algoritmo basado en el TL en combinación con el modelo de aprendizaje y servicio. El enfoque integra la implementación de un modelo preentrenado el cual se ajusta a la tarea específica al combinar la evaluación de su impacto en el aprendizaje con la aplicación en el servicio comunitario o profesional. En este caso, se utiliza BERT, especializado en el procesamiento del lenguaje natural (NLP) el cual genera valor en las actividades de servicio (Castillejos, 2022).

Modelo Matemático de Optimización Aplicado al Fine-Tuning de BERT.

El modelo matemático explica, de manera accesible, cómo se ajusta el modelo BERT para su aplicación en tareas educativas, tales como la clasificación de textos académicos o la entrega de retroalimentación personalizada a los estudiantes. Esta adaptación se apoya en principios del aprendizaje supervisado y en técnicas de optimización que mejoran progresivamente el desempeño del modelo, siendo una de las más utilizadas el descenso de gradiente estocástico (SGD), muchas veces acompañado por algoritmos más sofisticados los cuales facilitan este proceso.

a) Función de Pérdida (Loss Function) (Ecuación 1)

La función de pérdida (L) cuantifica el error de las predicciones del diseño o modelo y las clases dadas. En tareas de clasificación se utiliza la pérdida de entropía cruzada:

$$\mathcal{L}(\theta) = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c})$$

Ecuación 1. Función de pérdida de entropía cruzada

En este modelo, N representa la cantidad total de ejemplos utilizados, mientras que C indica el número de clases posibles. La variable y_i , corresponde a la etiqueta real del ejemplo, y $\hat{y}_i$, refleja la probabilidad que el modelo BERT asigna a esa clase. Estos elementos permiten evaluar qué tan cerca están las predicciones del modelo respecto a la realidad.

b) Optimización por Descenso de Gradiente (Ecuación 2)

El objetivo es reducir la función de pérdida ajustando los parámetros θ del modelo BERT:

$$\theta := \theta - \eta \cdot \nabla_{\theta} \mathcal{L}(\theta)$$

Ecuación 2. Algoritmo de optimización por Descenso de Gradiente

En este caso, θ son los valores que el modelo ajusta durante el aprendizaje, η indica qué tan rápido se realizan esos ajustes, y $\nabla \mathcal{L}(\theta)$ muestra hacia dónde deben cambiarse esos valores para mejorar los resultados.

c) Regularización (Ecuación 3)

Para evitar el sobreajuste, se añade un término de regularización $L2$ a la función de pérdida:

$$\mathcal{L}_{total} = \mathcal{L}(\theta) + \lambda \cdot \|\theta\|^2$$

Ecuación 3. Función de pérdida con regularización $L2$

Donde λ es un parámetro que controla el nivel de penalización aplicado a los parámetros del modelo.

d) Evaluación del modelo

El desempeño del modelo ajustado se evalúa utilizando métricas como: Precisión (Accuracy), F1-Score y Recall y Precision. En resumen, las métricas utilizadas para evaluar el modelo incluyen la precisión, que indica cuántas predicciones fueron correctas; el F1-Score, que equilibra precisión y sensibilidad; y los valores de recall y precisión, que ayudan a entender qué tan bien el modelo detecta y clasifica correctamente los casos.

e) Aplicación en Contexto Educativo

En el ámbito educativo, este proceso facilita la adaptación del modelo BERT a diversas tareas, como la clasificación automática de las respuestas entregadas por los estudiantes, la generación de recomendaciones académicas personalizadas y el análisis de sus patrones de interacción. Este enfoque representa una valiosa herramienta que contribuye a la retroalimentación docente y a fortalecer el proceso de enseñanza-aprendizaje al ser dinámico, efectivo y centrado en las necesidades reales del alumno.

Desarrollo del método lógico

La propuesta se basa en aprovechar modelos ya entrenados, que luego se ajustan según los requerimientos de una tarea específica relacionada con el procesamiento del lenguaje natural (NLP). En este caso, se eligió BERT, un modelo ampliamente utilizado por su capacidad de comprender el contexto del lenguaje gracias al entrenamiento con grandes volúmenes de texto. La intención es adaptar esta herramienta tecnológica a las particularidades del ámbito educativo, facilitando su aplicación de manera concreta y pertinente.

Etapas del método

1. Identificación del problema: El punto de partida del proceso consistió en establecer como objetivo la clasificación de textos o documentos académicos en categorías específicas, de acuerdo con las necesidades del entorno educativo aplicado en el modelo.
2. Elección del modelo preentrenado (BERT): Para abordar esta tarea, se seleccionó el modelo BERT en su versión base, conocido por haber sido previamente entrenado con una extensa cantidad de datos textuales. Su arquitectura bidireccional capta el significado contextual de las palabras dentro de una oración, lo cual lo convierte en una opción adecuada del análisis de lenguaje en entornos educativos.
3. Preparación de los datos y tokenización: Antes de ser procesados por el modelo, los textos fueron transformados en secuencias de unidades lingüísticas conocidas como tokens, mediante el uso del tokenizador específico de BERT. Así el modelo interpreta adecuadamente la información y ofrece resultados coherentes en el marco del aprendizaje-servicio.

4. Ajuste fino del modelo (fine-tuning): Una vez tokenizados los datos, se procedió a ajustar las capas superiores del modelo BERT conforme a la tarea concreta de clasificación académica. El enfoque se centra en adaptar el comportamiento del modelo para que las recomendaciones generadas respondan a las necesidades formativas particulares de los estudiantes involucrados en actividades de aprendizaje-servicio.
5. Entrenamiento del modelo: El modelo se entrenó utilizando un volumen reducido de datos relevantes por cada tarea, aplicando técnicas de optimización basadas en descenso de gradiente, complementadas con estrategias de regularización orientadas a prevenir el sobreajuste y mantener la capacidad generalizadora del sistema.
6. Evaluación del rendimiento: Para medir la efectividad del modelo ajustado, se recurrió a indicadores clásicos de evaluación en inteligencia artificial, tales como precisión, recuperación (recall), puntuación F1 y exactitud general. En paralelo, se consideró el impacto pedagógico, evaluando el nivel de conocimiento alcanzado por los estudiantes durante las actividades prácticas desarrolladas en el marco del aprendizaje-servicio.
7. Aplicación práctica del modelo: El modelo desarrollado, basado en Transfer Learning y adaptado mediante BERT, se propone como una herramienta aplicable en contextos educativos y sociales. La implementación de este enfoque tiene como propósito fortalecer los procesos de aprendizaje, permitiendo una retroalimentación precisa y una experiencia formativa significativa en cada estudiante al mismo tiempo que potencia el valor de su contribución en proyectos de servicio comunitario.

Comprobación en lógica o lenguaje pseudo

Para facilitar la comprensión del proceso de aplicación del modelo BERT en contextos educativos, se ha diseñado un pseudocódigo utilizando la herramienta PSeInt. Esta representación visualiza de forma clara y ordenada cada paso del flujo de trabajo, integrando inteligencia artificial con estrategias pedagógicas orientadas a mejorar el aprendizaje de los estudiantes.

Algoritmo: Mejora del Aprendizaje con Transfer Learning (TL) en el Contexto Educativo

Entrada:

- Datos académicos de estudiantes (tareas, exámenes, interacciones)
- Modelo preentrenado (ejemplo: BERT)
- Recomendaciones personalizadas para cada estudiante
- Objetivo: Mejorar retroalimentación y adaptación del aprendizaje

Proceso:

1. Cargar el modelo preentrenado (BERT):
Cargar (BERT)
2. Preprocesar los datos educativos:
Preprocesar(Datos_Educativos) # Limpiar y transformar los datos de tareas, exámenes, etc.
3. Aplicar Transfer Learning para adaptar el modelo:
AdaptarModelo(BERT, Datos_Educativos)
4. Clasificar textos académicos:
Resultados = ClasificarTextos(Datos_Educativos, BERT) # Clasificar tareas y exámenes de estudiantes
5. Analizar el desempeño de los estudiantes:
Para cada estudiante en Resultados:
Desempeño = EvaluarDesempeño(estudiante) # Analizar calificaciones, tiempo de respuesta, interacciones
Retroalimentación = GenerarRetroalimentación(Desempeño) # Retroalimentación personalizada basada en desempeño
6. Personalizar las recomendaciones:
Para cada estudiante en Resultados:
Recomendaciones = GenerarRecomendaciones(Desempeño) # Sugerir actividades o materiales adaptados
7. Ajustar las estrategias pedagógicas según las interacciones:
Para cada interacción en InteraccionesEstudiantes:
AjustarEstrategias(Interacción) # Modificar la enseñanza en tiempo real según las interacciones del estudiante
8. Verificar la precisión y calidad de las evaluaciones:
Precisión = CalcularPrecisión(Resultados, Evaluaciones) # Evaluar la precisión de las recomendaciones y retroalimentación
9. Mostrar resultados:
Mostrar (Resultados, Retroalimentación, Recomendaciones) # Presentar los resultados a los estudiantes y educadores
Salida:
 - Evaluación personalizada de cada estudiante
 - Recomendaciones ajustadas a las necesidades individuales
 - Mejorada calidad de las evaluaciones y retroalimentación

Detalle de cada tarea desarrollada

Primero, cargar el modelo preentrenado (BERT): Para agilizar el proceso se utiliza un modelo preentrenado como BERT el cual evita comenzar desde cero y ahorra tiempo y recursos en el entrenamiento de un nuevo modelo. Segundo, preprocesar los datos educativos: Los datos, como las tareas, exámenes e interacciones de los estudiantes, son limpiados y transformados para que puedan ser procesados de manera efectiva por el modelo. Tercero, aplicar Transfer Learning: En este paso, se adapta el modelo preentrenado para realizar tareas específicas, como clasificar o hacer predicciones con los datos de los estudiantes. Cuarto, clasificar textos académicos: Se clasifican las respuestas de los estudiantes, analizando sus tareas o exámenes para comprender mejor sus

conocimientos y habilidades. Quinto, analizar el desempeño: se evalúa el rendimiento de cada estudiante, considerando cómo les ha ido en las tareas y cómo interactúan con los materiales educativos. Sexto, personalizar las recomendaciones: Según las áreas identificadas, se generan recomendaciones específicas para cada estudiante, ayudando a enfocarse en sus necesidades de mejora. Séptimo, ajustar estrategias pedagógicas: Las estrategias de enseñanza se ajustan de manera dinámica, basándose en las interacciones de los estudiantes y en cómo van progresando. Octavo, verificar la precisión: Se verifica si las recomendaciones y retroalimentación son precisas y efectivas, asegurando que realmente aporten valor al proceso educativo. Noveno, mostrar resultados: Finalmente, se presentan los resultados a los estudiantes y educadores a fin de mejorar el aprendizaje en futuros ciclos.

RESULTADOS

El estudio analizó cómo el uso de Transfer Learning (TL) puede mejorar el aprendizaje en el contexto educativo, especialmente en el marco de aprendizaje y aprendizaje servicio. Así, se implementó un algoritmo basado en modelos preentrenados como BERT, que clasifica textos académicos y optimiza el proceso de retroalimentación hacia los estudiantes. Los resultados obtenidos demostraron un aumento significativo en la precisión y calidad de las evaluaciones, lo que respalda la idea de que combinar el TL con métodos educativos mejora el aprendizaje.

Uno de los aspectos más significativos observados en este estudio fue la capacidad del modelo para adaptarse con facilidad a nuevas tareas educativas, incluso cuando se tiene una cantidad mínima de datos. Esto permite evitar entrenamientos complejos desde cero y agiliza su aplicación en entornos educativos reales. Además, el sistema se ajusta de manera progresiva a las interacciones de los estudiantes, ofreciendo una retroalimentación precisa y ajustada a sus necesidades al identificar oportunamente las áreas donde requieren mayor apoyo.

Los estudiantes reciben recomendaciones más personalizadas al reconocer el proceso de enseñanza-aprendizaje y reconocen una experiencia más flexible y centrada en cada uno. También, los resultados mostraron cómo la combinación de inteligencia artificial con aprendizaje por transferencia tiene potencial para transformar la educación, al fomentar un acompañamiento cercano e incrementar las posibilidades de éxito académico.

Además, el modelo ajustado mediante TL se integró fácilmente en los sistemas educativos existentes, sin requerir una reconstrucción compleja de las plataformas digitales. Así se facilita la adopción de la tecnología por parte de las instituciones educativas al promover un aprendizaje más inclusivo y equitativo.

La manera en que los estudiantes se relacionan con el material educativo y entre ellos mismos puede ser un factor determinante del éxito en este tipo de modelos. El uso de BERT detecta patrones frecuentes en el comportamiento de los estudiantes, lo cual facilita anticiparse a posibles dificultades y adaptar las estrategias de enseñanza de forma oportuna. De este modo, la inteligencia artificial incide en el proceso de aprendizaje mientras contribuye a fortalecer un ambiente más dinámico, participativo y colaborativo en el aula.

Finalmente, sería valioso investigar más sobre cómo la inteligencia artificial y el aprendizaje servicio por transferencia impactan aspectos como la motivación y la colaboración en línea, para obtener una visión más completa del proceso educativo.

DISCUSIÓN

El uso del aprendizaje por transferencia (Transfer Learning) en el ámbito educativo se presenta como una valiosa oportunidad del avance hacia una enseñanza personalizada. Al trabajar con modelos ya entrenados, como BERT, es posible adaptarse a nuevas tareas sin necesidad de grandes volúmenes de datos, lo cual resulta especialmente útil en instituciones que cuentan con recursos limitados. La capacidad de adaptación genera retroalimentación ágil y precisa al favorecer evaluaciones efectivas y permitir a los docentes ajustar sus estrategias según las necesidades particulares de cada estudiante. Asimismo, al reducir los requerimientos técnicos, se hace más accesible la incorporación de herramientas de inteligencia artificial en distintos entornos educativos, ampliando así las posibilidades de ofrecer experiencias de aprendizaje-servicio ajustadas a las realidades de un mayor número de estudiantes (Taye, 2023; Shea et al., 2022).

También, la incorporación de esta tecnología plantea desafíos en diversos contextos. Uno es la necesidad de adaptar los modelos a las realidades educativas y culturales de cada contexto, ya que no existen soluciones universales. Además, para que las herramientas se implementen de manera efectiva, es imprescindible que las instituciones cuenten con los recursos adecuados y, sobre todo, con profesionales capacitados quienes las integran en la práctica docente. Así, implica invertir en

formación continua en los educadores, de modo que puedan aprovechar estas tecnologías sin perder de vista los objetivos pedagógicos. También es importante recordar que, por muy avanzados que sean estos sistemas, no deben reemplazar el vínculo humano entre docentes y estudiantes, ya que ese contacto sigue siendo un pilar fundamental del aprendizaje. Por ello, el uso del aprendizaje por transferencia debe equilibrarse cuidadosamente, valorando tanto el aporte tecnológico como la dimensión humana del proceso educativo (Drewery & Lollar, 2024; Lauriola et al., 2022).

En la segunda década del siglo XXI, el aprendizaje por transferencia (Transfer Learning) se perfila como una herramienta la cual impulsa cambios significativos en el ámbito educativo. La capacidad de personalizar la enseñanza y mejorar tanto las evaluaciones como la retroalimentación lo convierte en un recurso de gran valor dirigido a docentes e instituciones. Al trabajar con modelos previamente entrenados, como BERT, se reduce la necesidad de disponer de grandes cantidades de datos, lo que facilita su aplicación en contextos con recursos limitados. Así, desde la flexibilidad, es posible adaptar las estrategias pedagógicas de forma precisa a las necesidades individuales de cada estudiante, enriqueciendo así la experiencia formativa. Los resultados obtenidos en esta investigación muestran que el uso de TL contribuye a mejorar la precisión en los procesos de evaluación y genera recomendaciones oportunas, alineadas con el perfil y ritmo de aprendizaje de cada alumno. (Taye, 2023).

Además, al combinar el aprendizaje por transferencia con el análisis de las interacciones entre los estudiantes, es posible ofrecer una retroalimentación más precisa y personalizada. La integración comprende tanto el mejorar los comportamientos y necesidades del alumnado como la identificación temprana de áreas que requieren mayor apoyo. Así, el proceso de enseñanza se adapta de forma dinámica y enfoca los requerimientos del estudiante. Así es posible ajustar las estrategias pedagógicas en tiempo real lo cual facilita a los docentes el responder con mayor flexibilidad a las distintas realidades del aula y fortalecer las experiencias de aprendizaje-servicio (ApS) (Castro & Gómez, 2022; Pinto & Costa-Ramallo, 2023).

Asimismo, destaca la facilidad con que los modelos preentrenados se integran en las plataformas educativas ya existentes, evitando la necesidad de rediseñar completamente las infraestructuras tecnológicas (Hernández, 2025). Así, la adopción de tecnologías basadas en inteligencia artificial y Transfer Learning se hace accesible ante las instituciones educativas (Arteaga-Tuba, 2024). También, el uso de TL abre nuevas oportunidades de la innovación pedagógica al promover la educación inclusiva, personalizada y ofrecer a los estudiantes la experiencia de aprendizaje ajustada a sus

ritmos y estilos. En definitiva, esta metodología mejora la calidad del proceso educativo al posibilitar ser eficiente, accesible y alineado con las exigencias de la era digital.

REFERENCIAS BIBLIOGRÁFICAS

- Arteaga-Tuba, G. (2024). Recursos tecnológicos para el aprendizaje en el marco de la educación inclusiva ecuatoriana. *Cienciamatria. Revista Interdisciplinaria de Humanidades, Educación, Ciencia y Tecnología*, 10(18), 289-312. <https://doi.org/10.35381/cm.v10i18.1272>
- Castillejos, B. (2022). Inteligencia artificial y entornos personales de aprendizaje: atentos al uso adecuado de los recursos tecnológicos de los estudiantes universitarios. *Educación*, 31(60), 9-24. <https://doi.org/10.18800/educacion.202201.001>
- Castro, E., & Gómez, R. (2022). Análisis envolvente de datos de las plataformas educativas por área académica. *Apertura (Guadalajara, Jal.)*, 14(2), 92-109. <https://doi.org/10.32870/ap.v14n2.2199>
- Drewery, M., & Lollar, J. (2024). Undergraduates' perceptions of the value of service-learning. *Frontiers in Education*, 9, 1330456. <https://doi.org/10.3389/feduc.2024.1330456>
- Hernández, L. (2025). Gestión de una plataforma educativa virtual con inteligencia artificial y su adecuación funcional en el proceso de aprendizaje. *European Public & Social Innovation Review*, 10, 01-17. <https://doi.org/10.31637/epsir-2025-694>
- Lauriola, I., Lavelli, A., & Aiolli, F. (2022). An introduction to Deep Learning in Natural Language Processing: Models, techniques, and tools, *Neurocomputing*, 470, 443-456. <https://doi.org/10.1016/j.neucom.2021.05.103>
- Pinto, J., & Costa-Ramvalho, S. (2023). Effects of service-learning as opposed to traditional teaching-learning contexts: a pilot study with three different courses. *Frontiers in Education*, 8, 1185469. <https://doi.org/10.3389/feduc.2023.1185469>
- Shea, L., Harkins, D., Ray, S., & Grenier, L. (2022). How Critical is Service-Learning Implementation? *Journal of Experiential Education*, 46(2), 197-214. <https://doi.org/10.1177/10538259221122738>

Tarazona, C., Martínez-Usarralde, M. J., & Carbonell, A. (2024). Revisión sistemática del aprendizaje-servicio digital en instituciones de educación superior en Europa. *Revista Mexicana de Investigación Educativa*, 29(103), 801-827.

<https://ojs.rmie.mx/index.php/rmie/article/view/2/2>

Taye, M. (2023). Understanding of machine learning with deep learning: Architectures, workflow, applications and future directions. *Computers*, 12(5), 91.

<https://doi.org/10.3390/computers12050091>

Conflicto de intereses

Los autores declaran no tener conflictos de intereses.

Contribución de los autores

Los autores participaron en el diseño y redacción del artículo, en la búsqueda y análisis de la información contenida en la bibliografía consultada.



Esta obra está bajo una licencia Creative Commons Reconocimiento-NoComercial 4.0 Internacional