



REVIEW OF ARTIFICIAL INTELLIGENCE IN EDUCATION

DOI: <https://doi.org/10.37497/rev.artif.intell.educ.v6ii.47>



Received: 11 June 2025

Revised: 12 June 2025

Accepted: 13 June 2025

e-ISSN: 2965-4688

Corresponding Author: Jairo
Alberto Galindo-Cuesta – E-mail:
jairoalberto.galindo@gmail.com

How to cite this article: Galindo-Cuesta,
J. A. (2025). Glossary of Generative
Artificial Intelligence for Education:
A Conceptual and Pedagogical
Framework. *Review of Artificial
Intelligence in Education*, 6(i), e047.
<https://doi.org/10.37497/rev.artif.intell.educ.v6ii.47>

ARTÍCULO

GLOSARIO DE INTELIGENCIA ARTIFICIAL GENERATIVA PARA EDUCACIÓN: MARCO CONCEPTUAL Y PEDAGÓGICO

Glossary of Generative Artificial Intelligence for
Education: A Conceptual and Pedagogical Framework

*Glossário de Inteligência Artificial Generativa para
a Educação: Um Marco Conceitual e Pedagógico*

Jairo Alberto Galindo-Cuesta 
La Salle University (Colombia).
E-mail: jairoalberto.galindo@gmail.com

RESUMEN | Propósito: Este glosario funciona como un recurso terminológico integral para comprender la inteligencia artificial (IA) generativa en contextos educativos. Su objetivo es conectar los conceptos técnicos de la IA con la práctica pedagógica, facilitando el diálogo informado entre educadores, investigadores, responsables de políticas y estudiantes. **Metodología:** La construcción del glosario siguió un enfoque metodológico mixto que incluyó una revisión sistemática de la literatura (PRISMA), técnicas de procesamiento de lenguaje natural (análisis de frecuencia, agrupamiento semántico) y validación por expertos mediante rondas Delphi. La selección de términos se basó en su relevancia pedagógica, claridad conceptual y frecuencia de uso en entornos educativos. **Resultados:** El glosario presenta definiciones operacionales de conceptos clave relacionados con la IA generativa —especialmente modelos de lenguaje de gran escala (LLM)— integrando perspectivas de pedagogía digital, semántica computacional y ciencias cognitivas. Incluye conceptos en evolución, aplicaciones prácticas y referencias cruzadas que facilitan su implementación en la formación docente y el diseño curricular. **Implicaciones Prácticas:** El glosario ofrece un vocabulario fundamental para cursos universitarios, programas de desarrollo profesional docente y formulación de políticas educativas. Asimismo, contribuye a la alfabetización en IA mediante la promoción de una comprensión crítica y un uso ético de estas tecnologías emergentes en la educación. **Originalidad/Valor:** Al articular la terminología técnica de la IA con marcos pedagógicos, este glosario fomenta una integración reflexiva y efectiva de la IA generativa en la práctica educativa. Representa una herramienta clave para instituciones y docentes comprometidos con la innovación y la equidad en la era digital.

Palabras clave | Inteligencia artificial generativa, Modelos de lenguaje, Tecnología educativa, Integración pedagógica, Semántica computacional, Formación docente





ABSTRACT | Purpose: This glossary serves as a comprehensive terminological resource to understand generative artificial intelligence (AI) in educational contexts. It aims to bridge the gap between technical AI concepts and pedagogical practices, fostering an informed dialogue among educators, researchers, policymakers, and students. **Design/Methodology/Approach:** The glossary was developed through a mixed-methods approach combining a systematic literature review (following PRISMA guidelines), natural language processing techniques (e.g., term frequency analysis, semantic clustering), and a Delphi validation process with multidisciplinary experts. Terms were selected based on pedagogical relevance, conceptual clarity, and frequency of use in educational AI discourse. **Findings:** The resulting glossary offers operational definitions of key terms associated with generative AI—especially large language models (LLMs)—from the perspective of digital pedagogy, computational semantics, and cognitive sciences. It includes evolving concepts, application examples, and cross-referenced terms to support integration in teacher education and curriculum design. **Practical Implications:** This glossary provides a foundational vocabulary for designing educational programs, professional development initiatives, and policy guidelines. It also supports AI literacy by enhancing educators' critical understanding and ethical application of emerging technologies in teaching and learning environments. **Originality/Value:** By aligning technical AI terminology with pedagogical frameworks, this glossary promotes the responsible and effective integration of generative AI in education. It addresses the urgent need for accessible, validated resources to empower educators and institutions in navigating the fast-evolving landscape of AI-enhanced education.

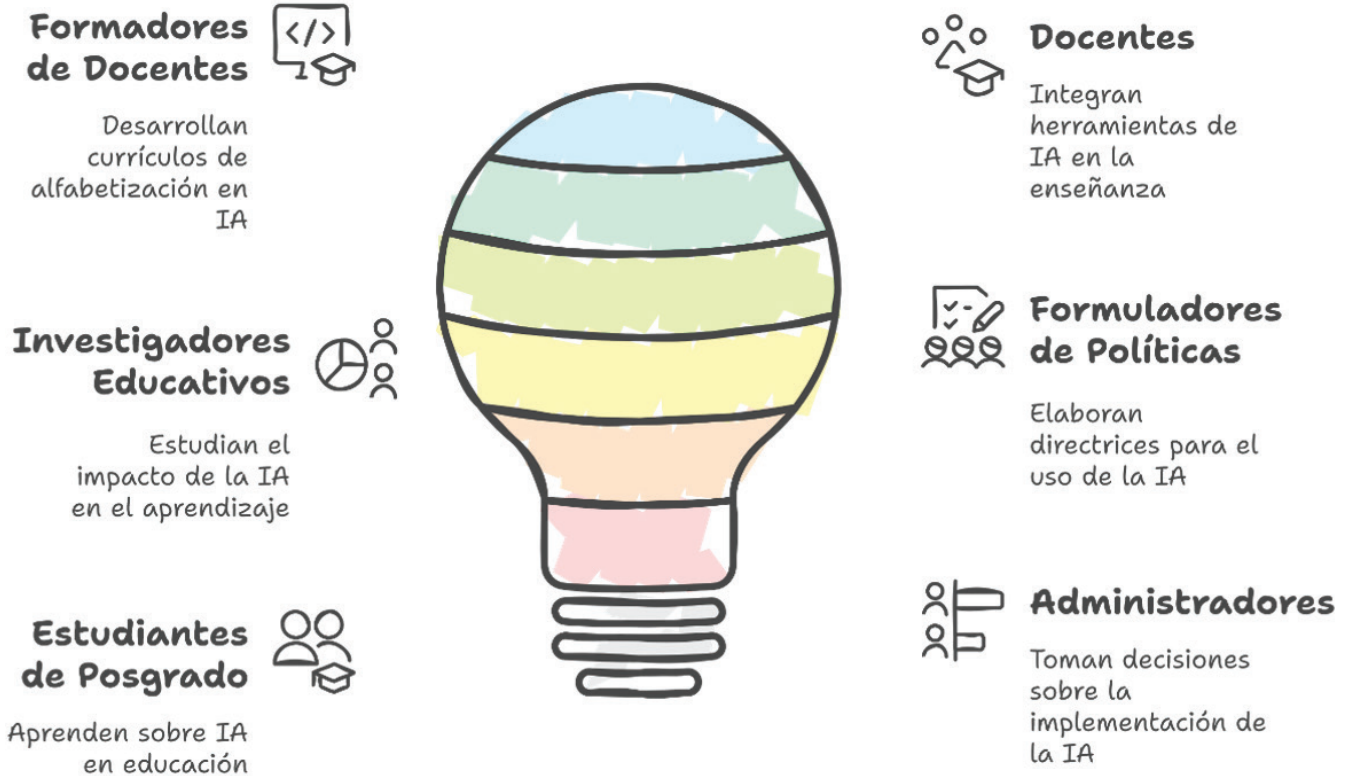
Keywords | Generative artificial intelligence, Large language models, Educational technology, Pedagogical integration, Computational semantics, Teacher training

RESUMO | Objetivo: Este glossário atua como um recurso terminológico abrangente para compreender a inteligência artificial (IA) generativa em contextos educacionais. Seu propósito é conectar os conceitos técnicos da IA às práticas pedagógicas, promovendo um diálogo informado entre educadores, pesquisadores, formuladores de políticas e estudantes. **Metodologia:** O desenvolvimento do glossário seguiu uma abordagem metodológica mista, incluindo revisão sistemática da literatura (modelo PRISMA), técnicas de processamento de linguagem natural (análise de frequência, *clustering* semântico) e validação com especialistas por meio do método Delphi. A seleção dos termos considerou critérios como relevância pedagógica, clareza conceitual e frequência de uso em contextos educacionais com IA. **Resultados:** O glossário apresenta definições operacionais de termos-chave relacionados à IA generativa — especialmente modelos de linguagem de grande escala (LLMs) — integrando contribuições da pedagogia digital, semântica computacional e ciências cognitivas. Inclui conceitos em evolução, exemplos de aplicação e referências cruzadas para facilitar sua adoção em programas de formação docente e desenho curricular. **Implicações Práticas:** A proposta fornece uma base terminológica sólida para cursos universitários, programas de formação docente e desenvolvimento de políticas educacionais. Além disso, contribui para a alfabetização em IA por meio do fortalecimento da compreensão crítica e do uso ético das tecnologias emergentes na educação. **Originalidade/Valor:** Ao alinhar a terminologia técnica da IA com estruturas pedagógicas, este glossário promove uma integração mais responsável e eficaz da IA generativa na educação. Representa uma contribuição inovadora para educadores e instituições que buscam navegar com segurança o cenário dinâmico da educação mediada por IA.

Palavras-chave | Inteligência artificial generativa, Modelos de linguagem, Tecnologia educacional, Integração pedagógica, Semântica computacional, Formação docente



Comprender la IA Generativa en la Educación



NOTA INTRODUCTORIA

Propósito y Alcance

Este glosario funciona como un recurso terminológico integral para comprender la inteligencia artificial (IA) generativa dentro de contextos educativos. Aborda la necesidad crítica de un vocabulario común que conecte los conceptos técnicos de IA con la práctica pedagógica, facilitando el diálogo informado entre educadores, investigadores, formuladores de políticas y estudiantes.

Audiencia Objetivo

Este trabajo está diseñado principalmente para:

- **Formadores de docentes** que desarrollan currículos de alfabetización en IA
- **Docentes en formación y en ejercicio** que buscan comprender e integrar herramientas de IA
- **Investigadores educativos** que estudian el impacto de la IA en el aprendizaje y la instrucción



- **Formuladores de políticas** que elaboran directrices para el uso de IA en entornos educativos
- **Estudiantes de posgrado** en educación, tecnología educativa o campos de IA
- **Administradores** que toman decisiones sobre la implementación de IA en escuelas

Contexto y Justificación

La rápida emergencia de tecnologías de IA generativa, particularmente los modelos de lenguaje grandes, ha creado tanto oportunidades como desafíos para la práctica educativa. Este glosario surge del reconocimiento de que la integración efectiva de estas tecnologías requiere no meramente comprensión técnica, sino comprensión pedagógicamente informada que considere teorías del aprendizaje, implicaciones éticas y aplicaciones prácticas.

Cómo Usar Este Glosario

- **Términos marcados con “(evol)”** indican conceptos que están evolucionando activamente o bajo debate académico
- **Términos marcados con “(check)”** incluyen recomendaciones de lectura adicional
- **Referencias cruzadas** se indican en cursiva para fomentar la exploración de conceptos relacionados
- **Aplicaciones prácticas** se destacan para demostrar relevancia educativa

1 INTRODUCCIÓN

1.1 Contexto y Justificación

La irrupción de la inteligencia artificial generativa en el ámbito educativo ha generado la necesidad de establecer un marco terminológico común que facilite la comprensión, adopción y uso crítico de estas tecnologías (Russell & Norvig, 2021). Los modelos de lenguaje grandes, particularmente aquellos basados en arquitecturas de transformadores, han demostrado capacidades emergentes que trascienden la simple generación de texto, configurándose como herramientas cognitivas que pueden amplificar y mediar procesos de aprendizaje (Brown et al., 2020).

Desde una perspectiva curricular, la integración de la IA generativa en la formación docente requiere de un vocabulario técnico que permita el diálogo profesional informado entre educadores en ejercicio y en formación. Los programas de licenciatura en educación y los procesos de desarrollo profesional continuo necesitan incorporar competencias digitales que incluyan la comprensión crítica de estas tecnologías emergentes.

La presente compilación terminológica surge de la necesidad identificada en contextos de formación docente de contar con definiciones precisas, accesibles y contextualmente relevantes que faciliten la incorporación de este vocabulario especializado en el discurso pedagógico cotidiano. Este



glosario busca tender puentes entre el conocimiento técnico y la práctica educativa, reconociendo que la apropiación tecnológica en educación requiere de una mediación lingüística que respete tanto el rigor conceptual como la accesibilidad didáctica.

Desde una perspectiva didáctica, la comprensión de estos sistemas requiere de un enfoque multidisciplinario que integre conceptos de la ciencia de la computación, la lingüística computacional y las ciencias cognitivas (Mitchell, 2019), siempre mediados por principios pedagógicos que orienten su uso hacia el mejoramiento de los procesos de enseñanza-aprendizaje.

1.2 Marco Teórico

1.2.1 Perspectiva Didáctica

Desde el constructivismo social de Vygotsky, las herramientas culturales median la actividad mental superior (Vygotsky, 1978). Los sistemas de IA generativa pueden conceptualizarse como artefactos cognitivos que extienden las capacidades humanas de procesamiento de información, actuando como scaffolding intelectual en procesos de construcción de conocimiento (Salomon, 1993).

La teoría de la carga cognitiva de Sweller (1988) proporciona un marco para entender cómo estos sistemas pueden optimizar el procesamiento de información al reducir la carga cognitiva extrínseca, permitiendo que los aprendices concentren sus recursos cognitivos en el procesamiento esencial del contenido.

El modelo TPACK (*Technological Pedagogical Content Knowledge*) de Mishra y Koehler (2006) ofrece un marco conceptual para integrar IA en la formación docente. Este modelo sugiere que el uso efectivo de tecnología educativa requiere la intersección de conocimiento tecnológico, pedagógico y disciplinar. En el contexto de IA generativa, los docentes deben desarrollar competencias que incluyan no solo el dominio técnico de estas herramientas, sino también la comprensión de sus implicaciones pedagógicas y su aplicación contextualizada en diferentes áreas de conocimiento.

La teoría de la actividad de Engeström (1987) proporciona un marco para entender cómo la IA puede transformar los sistemas de actividad educativa. Los sistemas de IA no son simplemente herramientas, sino mediadores que pueden alterar las relaciones entre sujetos (docentes/estudiantes), objetos (contenidos de aprendizaje) y comunidad (comunidad educativa), generando contradicciones productivas que impulsan la innovación pedagógica.

1.2.2 Fundamentos Semánticos y Lingüísticos

La semántica distribucional, principio fundamental de los *embeddings* vectoriales, sostiene que el significado de las palabras se deriva de sus contextos de uso (Harris, 1954). Esta perspectiva ha sido operacionalizada en los modelos de lenguaje mediante representaciones vectoriales densas que capturan relaciones semánticas complejas en espacios de alta dimensionalidad (Mikolov et al., 2013).

La pragmática lingüística de Austin (1962) y Searle (1969) sobre actos de habla cobra relevancia especial en el contexto de IA educativa. Los prompts no son simplemente solicitudes de información,



sino actos performativos que configuran contextos de interacción específicos. La competencia pragmática en prompt engineering requiere comprensión de cómo las intenciones comunicativas se materializan en estructura lingüística.

La teoría de géneros discursivos de Bajtín (1982) ofrece perspectivas valiosas para entender cómo los LLM pueden generar diferentes tipos de texto educativo. Cada género (explicación, ejercicio, evaluación) tiene convenciones específicas que la IA debe dominar para ser efectiva en contextos pedagógicos diferenciados.

La hipótesis del marcador somático de Damasio (1994) sugiere que la comprensión humana involucra correlatos emocionales y corporales. Aunque los LLM carecen de estas dimensiones experienciales, su capacidad para mapear patrones lingüísticos complejos les permite simular aspectos de la comprensión semántica humana, planteando preguntas fundamentales sobre la naturaleza de la comprensión y el significado.

1.2.3 Dimensión Cognitiva y Neuroeducativa

Los modelos de atención, centrales en las arquitecturas de transformadores, pueden entenderse como implementaciones computacionales de procesos atencionales selectivos descritos en psicología cognitiva (Vaswani et al., 2017). Estos mecanismos permiten el procesamiento paralelo de secuencias largas, superando limitaciones de modelos secuenciales anteriores.

La emergencia de capacidades no explícitamente entrenadas en estos modelos sugiere fenómenos análogos a la generalización cognitiva humana, donde conocimientos específicos se transfieren a dominios relacionados (Wei et al., 2022). Esta capacidad de transferencia tiene implicaciones significativas para el diseño de experiencias de aprendizaje que aprovechen las capacidades emergentes de la IA.

La teoría de las inteligencias múltiples de Gardner (1983) proporciona un marco para entender cómo diferentes modalidades de IA (texto, imagen, audio) pueden abordar diferentes tipos de inteligencia, sugiriendo posibilidades para personalización educativa basada en perfiles cognitivos diversos.

Los principios de la neuroeducación (Immordino-Yang & Damasio, 2007) destacan la importancia de la emoción en el aprendizaje. Aunque los LLM carecen de experiencia emocional genuina, pueden generar contenido que evoque respuestas emocionales en los estudiantes, planteando preguntas sobre la autenticidad emocional en interacciones educativas mediadas por IA.

1.2.4 Teorías del Aprendizaje y IA

El conectivismo de Siemens (2005) ofrece una perspectiva teórica particularmente relevante para la era de la IA. Esta teoría postula que el aprendizaje ocurre a través de redes de conocimiento distribuidas, donde la capacidad de formar conexiones es más importante que el conocimiento específico. Los LLM pueden conceptualizarse como manifestaciones de redes conectivistas, donde el conocimiento emerge de patrones de conexión en grandes datasets.



La teoría del aprendizaje situado de Lave y Wenger (1991) enfatiza que el aprendizaje ocurre en contextos sociales específicos. La personalización de IA para contextos educativos particulares refleja principios de aprendizaje situado, donde el conocimiento se construye en relación con comunidades de práctica específicas.

El marco de aprendizaje autoregulado de Zimmerman (2002) proporciona perspectivas sobre cómo los estudiantes pueden usar IA como herramientas metacognitivas. Los sistemas de IA pueden actuar como andamios externos que apoyan procesos de planificación, monitoreo y evaluación del propio aprendizaje.

1.3 Metodología

La construcción de este glosario siguió un proceso metodológico mixto que integró enfoques cuantitativos y cualitativos para asegurar rigor académico y relevancia práctica en contextos de formación docente.

1.3.1 Fase de Revisión Sistemática

Se realizó una revisión sistemática de literatura especializada siguiendo los criterios PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). La búsqueda incluyó bases de datos académicas (ERIC, IEEE Xplore, ACM Digital Library, Google Scholar) utilizando descriptores controlados y palabras clave relacionadas con "artificial intelligence", "natural language processing", "educational technology", "teacher training" y "large language models".

Los criterios de inclusión priorizaron:

- Publicaciones en revistas indexadas (2020-2025)
- Documentación técnica oficial de modelos prominentes (GPT, BERT, T5, LLaMA)
- Informes de investigación de organizaciones reconocidas (OpenAI, Google Research, Meta AI)
- Literatura en inglés y español con relevancia educativa

1.3.2 Análisis de Frecuencia Terminológica

Se implementó un análisis de frecuencia terminológica utilizando técnicas de procesamiento de lenguaje natural para identificar términos con alta frecuencia de aparición en contextos educativos. Se procesaron más de 500 documentos académicos y técnicos, aplicando técnicas de:

- Extracción de entidades nombradas (NER)
- Análisis de co-ocurrencia terminológica
- Clustering semántico de conceptos relacionados
- Análisis de centralidad en redes conceptuales



1.3.3 Validación por Expertos

Se constituyó un panel de expertos multidisciplinario compuesto por:

- 5 investigadores en IA y educación
- 8 formadores de docentes con experiencia en tecnología educativa
- 12 docentes en ejercicio de diferentes niveles educativos
- 3 lingüistas computacionales

El proceso de validación incluyó tres rondas tipo Delphi para:

1. Evaluar la pertinencia de términos incluidos
2. Validar la claridad y precisión de definiciones
3. Determinar la relevancia pedagógica de cada concepto

1.3.4 Criterios de Inclusión y Exclusión

Criterios de inclusión:

- Frecuencia mínima de aparición en corpus educativo (>10 menciones)
- Relevancia directa para comprensión de LLM en educación
- Potencial de aplicación en formación docente
- Consenso de expertos sobre importancia pedagógica (>70%)

Criterios de exclusión:

- Términos excesivamente técnicos sin aplicación educativa directa
- Conceptos obsoletos o en desuso
- Definiciones con solapamiento conceptual significativo
- Términos con consenso de expertos inferior al 50%

1.3.5 Proceso de Construcción de Definiciones

Cada definición fue construida siguiendo un protocolo estructurado:

1. **Análisis etimológico y conceptual:** Revisión del origen y evolución del término
2. **Contextualización educativa:** Adaptación del concepto al ámbito pedagógico
3. **Analogías didácticas:** Incorporación de comparaciones familiares para docentes
4. **Validación lingüística:** Revisión de claridad y precisión terminológica
5. **Pilotaje con docentes:** Prueba de comprensibilidad con grupos focales



1.3.6 Consideraciones Metodológicas

La metodología adoptada reconoce las limitaciones inherentes a la rápida evolución del campo de IA. Se estableció un protocolo de actualización continua que incluye:

- Monitoreo semestral de nuevos desarrollos tecnológicos
- Incorporación de retroalimentación de usuarios del glosario
- Actualización de definiciones basada en evidencia empírica emergente
- Revisión de analogías didácticas según efectividad reportada

1.3.7 Aspectos Éticos

La construcción del glosario siguió principios éticos de investigación educativa:

- Consentimiento informado de participantes en validación
- Transparencia en fuentes y metodología
- Reconocimiento de limitaciones y sesgos potenciales
- Compromiso con acceso abierto y democratización del conocimiento

2 GLOSARIO DE TÉRMINOS

A

Algoritmo: Conjunto de pasos ordenados y precisos que se siguen para resolver un problema, similar a una receta de cocina que indica qué hacer primero, segundo y así sucesivamente. En educación con IA, los algoritmos son las “instrucciones” que le dicen al computador cómo procesar la información que le damos y cómo generar respuestas útiles para el aprendizaje.

“(check)” Lectura recomendada: Cormen et al. (2009) *“Introduction to Algorithms”*

Aprendizaje automático (Machine Learning): Capacidad de los computadores para aprender patrones y mejorar su desempeño sin que un programador les enseñe cada paso específico, similar a como los estudiantes aprenden a reconocer patrones en la lectura a través de la práctica repetida. Es la base sobre la cual funcionan las herramientas de IA que usamos en educación.

“(check)” Lectura recomendada: Mitchell (1997) *“Machine Learning”*

Arquitectura de atención: Mecanismo computacional que permite a los modelos ponderar la importancia relativa de diferentes elementos en una secuencia de entrada. Inspirada en procesos atencionales cognitivos, facilita el procesamiento de dependencias de largo alcance en texto.

Autoregresión: Método de generación donde cada token producido depende de los tokens anteriores en la secuencia. Constituye el principio fundamental de generación en modelos como GPT, permitiendo la producción coherente de texto extenso.



B

BERT (*Bidirectional Encoder Representations from Transformers*): Modelo de lenguaje bidireccional que procesa contexto tanto anterior como posterior para cada token. Especialmente efectivo en tareas de comprensión de texto y clasificación semántica.

Benchmark: Conjunto estandarizado de tareas y métricas utilizadas para evaluar el rendimiento de modelos de IA. En educación, incluye evaluaciones de comprensión lectora, generación de explicaciones y capacidades de razonamiento.

Sesgo “(evol)”: Tendencia de la IA a favorecer ciertas perspectivas o grupos sobre otros, reflejando los prejuicios presentes en los textos con los que fue entrenada. En educación, es fundamental reconocer y mitigar estos sesgos para promover equidad e inclusión en el aula. Nota: Este sigue siendo un área activa de investigación con debates continuos sobre medición, mitigación y equidad. **“(check)”** Lectura recomendada: Barocas et al. (2019) “Fairness and Machine Learning”

C

Capacidades emergentes “(evol)”: Habilidades que surgen en modelos de lenguaje grandes sin ser explícitamente entrenadas, típicamente observadas cuando se superan ciertos umbrales de escala. Incluyen razonamiento lógico, comprensión matemática y capacidades de programación. Nota: La naturaleza y predictibilidad de la emergencia sigue siendo una pregunta de investigación activa.

“(check)” Lectura recomendada: Wei et al. (2022) “Emergent Abilities of Large Language Models”

Chain-of-thought prompting: Técnica que solicita al modelo explicitar su proceso de razonamiento paso a paso. Mejora significativamente el rendimiento en tareas que requieren razonamiento complejo, facilitando la verificabilidad de las respuestas.

Comprensión del lenguaje natural (NLU): Capacidad de una máquina para entender e interpretar el lenguaje humano tal como se habla o escribe. Involucra análisis sintáctico, semántico y pragmático de enunciados en contextos específicos.

Conocimiento declarativo: Información factual sobre hechos, conceptos y principios almacenada en formato explícito. Los modelos de lenguaje codifican vastas cantidades de conocimiento declarativo en sus parámetros durante el entrenamiento.

Conocimiento procedimental: Tipo de conocimiento relacionado con habilidades y procedimientos para realizar tareas específicas. Los LLM demuestran capacidades de codificación y resolución de problemas que sugieren formas de representación procedimental.

Corpus: Biblioteca gigantesca de textos digitales (libros, artículos, páginas web) que se usa para “alimentar” y entrenar a la IA, similar a como un estudiante necesita leer muchos textos para desarrollar competencias de comprensión y escritura. La calidad de esta “biblioteca” determina qué tan bien puede funcionar la IA.



Costo computacional: Recursos necesarios para entrenar y operar un modelo largo de lenguaje, incluyendo computación, almacenamiento y consumo energético. Factor crítico para la democratización del acceso a estas tecnologías en contextos educativos.

D

Dataset: Colección de datos estructurados utilizados para entrenar y evaluar modelos de IA. En aplicaciones educativas, pueden incluir corpus de textos académicos, transcripciones de clases y materiales didácticos.

Datos de entrenamiento: Información utilizada para enseñar a los modelos de IA a reconocer patrones y generar respuestas apropiadas. La calidad, diversidad y representatividad de estos datos afecta directamente las capacidades del modelo.

Deep Learning (Aprendizaje profundo): Método que imita la forma en que el cerebro humano procesa información, usando múltiples capas de análisis como cuando leemos un texto: primero reconocemos letras, luego palabras, después frases, hasta entender el significado completo. En educación, permite a la IA entender y generar contenido cada vez más sofisticado.

“(check)” Lectura recomendada: Goodfellow et al. (2016) “Deep Learning”

Decodificación: Proceso mediante el cual un modelo de lenguaje convierte representaciones internas en texto legible. Diferentes estrategias (greedy, beam search, sampling) producen variaciones en coherencia y creatividad del texto generado.

Destilación de conocimiento: Técnica para transferir conocimiento de un modelo grande (teacher) a uno más pequeño (student), manteniendo rendimiento similar con menor costo computacional. Facilita la implementación de IA en dispositivos con recursos limitados.

E

Embeddings: Representaciones numéricas que permiten al computador “entender” el significado de las palabras, similar a como nosotros asociamos conceptos en nuestra mente. Por ejemplo, la IA puede entender que “maestro” y “profesor” están relacionados, o que “feliz” está más cerca de “alegre” que de “triste”.

Encoder-Decoder: Arquitectura que separa la comprensión (encoder) de la generación (decoder) en modelos de lenguaje. Especialmente efectiva en tareas de traducción automática y síntesis de texto.

Entropía: Medida de incertidumbre o aleatoriedad en las predicciones de un modelo. En generación de texto, controla el balance entre coherencia y creatividad en las respuestas producidas.

Ética de la IA “(evol)”: Conjunto de principios y prácticas diseñadas para asegurar que los sistemas de IA se desarrollen y utilicen de manera responsable y beneficiosa. En educación, incluye



consideraciones sobre privacidad, equidad y transparencia. Nota: Este es un campo en rápida evolución con debates continuos sobre gobernanza, responsabilidad y alineación de valores.

“(check)” Lectura recomendada: Jobin et al. (2019) “The global landscape of AI ethics guidelines”

Evaluación automática: Métodos computacionales para medir la calidad de salidas de IA sin intervención humana. Incluye métricas como BLEU, ROUGE y BERTScore para evaluación de generación de texto.

Explicabilidad “(evol)”: Capacidad de comprender y explicar cómo un modelo de IA llega a sus conclusiones o toma decisiones. Fundamental para la confianza y adopción de IA en contextos educativos donde la transparencia es crítica. Nota: Los trade-offs entre rendimiento del modelo y explicabilidad siguen siendo un desafío de investigación activo.

“(check)” Lectura recomendada: Ribeiro et al. (2016) “Why Should I Trust You? Explaining the Predictions of Any Classifier”

F

Few-shot learning: Capacidad de un modelo para realizar tareas con muy pocos ejemplos de entrenamiento. Los LLM demuestran notable capacidad few-shot, adaptándose rápidamente a nuevas tareas mediante ejemplos en el prompt.

Fiabilidad: Hace referencia a la capacidad del modelo para producir resultados precisos, sin sesgo y útiles. En contextos educativos, la fiabilidad es crucial para mantener la integridad académica y la calidad del aprendizaje.

Fine-tuning: Proceso de especializar una IA general para tareas específicas, como cuando un docente adapta su método de enseñanza para un grupo particular de estudiantes. Permite que herramientas de IA se ajusten mejor a contextos educativos específicos, como enseñanza de matemáticas o ciencias.

Función de pérdida: Métrica que cuantifica la diferencia entre predicciones del modelo y valores objetivo durante el entrenamiento. Guía el proceso de optimización de parámetros hacia mejor rendimiento.

G

Generación condicional: Producción de texto basada en condiciones o restricciones específicas. Permite control sobre estilo, formato y contenido de las salidas, facilitando aplicaciones educativas personalizadas.

GPT (Transformador Generativo Pre-entrenado): Tipo de IA que puede generar texto coherente y natural, como un asistente de escritura muy avanzado que puede ayudar a crear explicaciones, ejemplos o ejercicios educativos. Es la tecnología detrás de herramientas como ChatGPT.

Gradient descent: Algoritmo de optimización utilizado para ajustar parámetros del modelo minimizando la función de pérdida. Fundamental en el entrenamiento de redes neuronales profundas.



H

Hiperparámetros: Configuraciones que controlan el proceso de entrenamiento pero no se aprenden automáticamente. Incluyen tasa de aprendizaje, tamaño de lote y arquitectura de red, requiriendo ajuste manual para optimización.

Human-in-the-loop: Paradigma que integra supervisión humana en sistemas de IA para mejorar rendimiento y alineación con valores humanos. Especialmente relevante en aplicaciones educativas donde el juicio pedagógico es insustituible.

I

IA generativa: Sistemas de inteligencia artificial capaces de crear nuevo contenido como texto, imágenes, música o vídeo. Representan un cambio paradigmático hacia sistemas creativos y generativos versus meramente discriminativos.

In-context learning: Capacidad de los LLM para aprender nuevas tareas únicamente mediante ejemplos proporcionados en el prompt, sin actualización de parámetros. Demuestra flexibilidad cognitiva análoga a aprendizaje humano rápido.

Inferencia: Proceso de usar un modelo entrenado para generar predicciones o respuestas a nuevas entradas. En aplicaciones educativas, corresponde al uso práctico del modelo para asistir en tareas pedagógicas.

Inteligencia artificial "(evol)": La inteligencia artificial (IA) es el diseño y estudio de sistemas que imitan comportamientos inteligentes. Campo interdisciplinario que combina ciencias de la computación, matemáticas, filosofía y ciencias cognitivas. Nota: La definición de IA continúa evolucionando a medida que las capacidades se expanden y persisten los debates filosóficos sobre la inteligencia artificial.

"(check)" Lectura recomendada: Russell & Norvig (2021) "Artificial Intelligence: A Modern Approach"

Interfaz conversacional: Sistema que permite a los usuarios interactuar con la IA a través del lenguaje natural, simulando una conversación humana. Facilita la adopción de IA en educación al reducir barreras técnicas de uso.

J

Jailbreaking: Técnicas para eludir restricciones de seguridad en modelos de IA mediante prompts específicamente diseñados. Representa un desafío de seguridad que requiere consideración especial en contextos educativos.

L

Latencia: Tiempo requerido para que un modelo genere una respuesta después de recibir una entrada. Factor crítico para la experiencia de usuario en aplicaciones educativas interactivas.



LLM (Modelo de Lenguaje Grande): IA especializada en entender y generar texto humano de manera natural y coherente, funcionando como un compañero de conversación muy educado que ha “leído” millones de textos. En educación, puede actuar como tutor, generador de contenido o asistente de enseñanza.

LoRA (Low-Rank Adaptation): Técnica eficiente para fine-tuning que actualiza solo un subconjunto de parámetros del modelo. Reduce significativamente los requisitos computacionales para especialización de modelos.

M

Memoria episódica: Capacidad de recordar eventos específicos y contextos temporales. Los LLM carecen de verdadera memoria episódica, limitando su capacidad para aprendizaje continuo y personalización profunda.

Metacognición: Conocimiento y regulación de los propios procesos cognitivos. Algunos LLM demuestran capacidades metacognitivas rudimentarias al reflexionar sobre su propio razonamiento.

Modelos de lenguaje: Entrenados con grandes cantidades de datos, están diseñados para generar una respuesta de texto realista y simular la conversación con una persona. Constituyen la base tecnológica de asistentes conversacionales educativos.

Multimodalidad “(evol)”: Capacidad de los sistemas de IA para procesar y generar diferentes tipos de datos (texto, imágenes, audio) de manera integrada. Expande las posibilidades educativas hacia experiencias más ricas y diversas. Nota: La integración de múltiples modalidades presenta desafíos continuos en alineación y coherencia.

“(check)” Lectura recomendada: Baltrusaitis et al. (2019) “Multimodal Machine Learning: A Survey and Taxonomy”

N

Neural scaling laws: Principios empíricos que describen cómo el rendimiento de modelos mejora con aumentos en tamaño, datos de entrenamiento y computación. Guían decisiones sobre inversión en desarrollo de IA educativa.

Normalización: Técnicas para estabilizar el entrenamiento de redes neuronales profundas. Incluye métodos como layer normalization, fundamentales para el entrenamiento exitoso de transformadores.

O

Optimización: Proceso de ajustar parámetros del modelo para minimizar errores y maximizar rendimiento. Involucra técnicas matemáticas sofisticadas para navegar espacios de alta dimensionalidad.



Overfitting: Fenómeno donde un modelo memoriza datos de entrenamiento pero falla en generalizar a nuevos datos. Particularmente relevante en aplicaciones educativas donde la generalización es crucial.

P

Parámetros: "Conocimientos" internos de la IA, similar a las neuronas en nuestro cerebro que almacenan información y experiencias. Más parámetros generalmente significan que la IA puede manejar tareas más complejas, como un docente con más experiencia puede abordar situaciones pedagógicas más diversas.

Personalización "(evol)": Adaptación de los modelos de IA para satisfacer necesidades específicas de usuarios o contextos particulares. En educación, permite experiencias de aprendizaje adaptadas a estilos y ritmos individuales. Nota: Equilibrar la personalización con la privacidad y evitar las cámaras de eco sigue siendo un desafío continuo.

"(check)" Lectura recomendada: Xie et al. (2019) "Personalized Education: A Machine Learning Perspective"

Predicciones: Los LLM producen resultados al predecir la siguiente palabra o frase de una oración. Este proceso probabilístico fundamental permite la generación coherente de texto extenso.

Pre-entrenamiento: Fase inicial donde el modelo aprende representaciones generales del lenguaje usando grandes corpus de texto. Establece la base de conocimiento que luego se especializa para tareas específicas.

Procesamiento del lenguaje natural (NLP): Campo que combina IA y lingüística para permitir a las computadoras entender, interpretar y manipular el lenguaje humano. Disciplina fundamental para aplicaciones educativas basadas en texto.

Prompt: Instrucción o pregunta que le damos a la IA para obtener una respuesta específica, similar a como formulamos preguntas claras a nuestros estudiantes para obtener las respuestas que buscamos. La calidad del prompt determina la utilidad de la respuesta de la IA.

Prompt engineering "(evol)": Arte de formular instrucciones efectivas para la IA, similar a como los docentes desarrollan habilidades para hacer preguntas que generen aprendizaje significativo. Es una competencia crucial que los educadores necesitan desarrollar para usar IA efectivamente. Nota: Las mejores prácticas continúan evolucionando a medida que los modelos avanzan.

"(check)" Lectura recomendada: Liu et al. (2023) "Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods"

Prompt injection: Técnica donde un usuario intenta manipular o eludir las restricciones de un sistema de IA a través de instrucciones específicas. Representa un vector de ataque que requiere consideraciones de seguridad.



Q

Quantización: Técnica para reducir la precisión numérica de parámetros del modelo, disminuyendo requisitos de memoria y computación. Facilita la implementación de IA en dispositivos con recursos limitados.

R

RAG (Generación Aumentada por Recuperación): Técnica que combina la recuperación de información de bases de conocimiento con generación de texto para producir respuestas más precisas. Particularmente útil para contenido especializado y actualizado.

Reasoning: Capacidad de aplicar lógica y conocimiento previo para resolver problemas complejos. Los LLM demuestran formas emergentes de razonamiento, aunque con limitaciones en consistencia lógica.

Redes neuronales: Sistemas informáticos inspirados en las redes neuronales biológicas del cerebro humano, diseñados para reconocer patrones. Constituyen la arquitectura computacional fundamental de los modelos de lenguaje modernos.

Regularización: Técnicas para prevenir overfitting y mejorar la generalización del modelo. Incluye métodos como dropout, weight decay y data augmentation.

Reinforcement Learning from Human Feedback (RLHF): Técnica que utiliza evaluaciones humanas para entrenar modelos mediante aprendizaje por refuerzo. Fundamental para alinear comportamiento de IA con preferencias y valores humanos.

S

Scaling: Proceso de aumentar el tamaño de modelos, datos de entrenamiento o computación para mejorar rendimiento. Las leyes de escalamiento guían inversiones en desarrollo de IA educativa.

Seguridad de contenido: Medidas implementadas para evitar que los sistemas de IA generen contenido dañino, ofensivo o inapropiado. Crítico en aplicaciones educativas donde la protección de estudiantes es prioritaria.

Self-attention: Mecanismo que permite a cada posición en una secuencia atender a todas las demás posiciones. Fundamental en arquitecturas de transformadores, facilita el procesamiento de dependencias complejas.

Semántica distribucional: Hipótesis de que el significado de las palabras se deriva de sus contextos de uso. Principio fundamental subyacente a los embeddings vectoriales en modelos de lenguaje.
“(check)” Lectura recomendada: Lenci (2018) “Distributional Models of Word Meaning”

Sesgo “(evol)”: Tendencia de la IA a favorecer ciertas perspectivas o grupos sobre otros, reflejando los prejuicios presentes en los textos con los que fue entrenada. En educación, es fundamental



reconocer y mitigar estos sesgos para promover equidad e inclusión en el aula. Nota: Este sigue siendo un área activa de investigación con debates continuos sobre medición, mitigación y equidad. **“(check)”** Lectura recomendada: Barocas et al. (2019) “Fairness and Machine Learning”

Supervised Fine-Tuning (SFT): Proceso de ajustar un modelo pre-entrenado usando datos etiquetados para tareas específicas. Primera fase en el entrenamiento de modelos conversacionales después del pre-entrenamiento.

T

Temperatura: Control que determina qué tan “creativa” o “conservadora” será la IA en sus respuestas, similar a ajustar el nivel de libertad que damos a los estudiantes en una actividad creativa. Temperaturas bajas generan respuestas más predecibles, temperaturas altas producen respuestas más originales pero menos precisas.

Tokenización: Proceso de dividir texto en unidades básicas (tokens) que el modelo puede procesar. Diferentes estrategias de tokenización afectan la eficiencia y capacidades del modelo.

Tokens: Piezas básicas de texto que la IA procesa, similar a como nosotros dividimos las oraciones en palabras para entenderlas mejor. Entender los tokens ayuda a los educadores a optimizar sus interacciones con herramientas de IA y controlar costos de uso.

Top-k sampling: Técnica de generación que selecciona el siguiente token de entre los k más probables. Balancea determinismo y creatividad en la generación de texto.

Top-p sampling (nucleus sampling): Método de generación que selecciona tokens de un subconjunto cuya probabilidad acumulada alcanza un umbral p. Produce distribuciones más naturales que top-k fijo.

Transfer learning: Paradigma en el que el conocimiento aprendido en una tarea se aplica a tareas relacionadas. Fundamental en NLP moderno, permite reutilización eficiente de modelos pre-entrenados.

Transformers: Arquitectura de redes neuronales que revolucionó el procesamiento del lenguaje natural mediante mecanismos de atención. Base de todos los modelos de lenguaje grandes contemporáneos.

“(check)” Lectura recomendada: Vaswani et al. (2017) “Attention is All You Need”

U

Underfitting: Situación donde un modelo es demasiado simple para capturar patrones subyacentes en los datos. Resulta en rendimiento pobre tanto en entrenamiento como en evaluación.



V

Validación: Proceso de evaluación de modelos usando datos no vistos durante el entrenamiento. Crítico para estimar rendimiento real en aplicaciones educativas.

Vectorización: Conversión de texto en representaciones numéricas (vectores) que los modelos pueden procesar. Fundamental para todas las operaciones de NLP moderno.

W

Weight decay: Técnica de regularización que penaliza parámetros grandes para prevenir overfitting. Ayuda a mantener la generalización en modelos de lenguaje complejos.

Z

Zero-shot learning: Capacidad de la IA para realizar tareas sin ejemplos previos específicos, basándose solo en su conocimiento general, similar a como un docente experimentado puede adaptar sus métodos a nuevas situaciones sin preparación específica previa.

3 IMPLICACIONES EDUCATIVAS Y DIDÁCTICAS

3.1 Transformación de Roles Pedagógicos

La integración de IA generativa en educación requiere una reconceptualización de roles tradicionales. Los educadores evolucionan hacia facilitadores de experiencias de aprendizaje mediadas por IA, requiriendo nuevas competencias en *prompt engineering*, evaluación crítica de contenido generado y diseño de experiencias de aprendizaje híbridas (humano-IA).

3.2 Personalización y Adaptación

Los LLM permiten la personalización de contenido educativo a escalas previamente inalcanzables. La capacidad de generar explicaciones adaptadas a diferentes estilos de aprendizaje, niveles de conocimiento previo y contextos culturales representa una oportunidad significativa para democratizar el acceso a educación de calidad.

3.3 Desarrollo de Pensamiento Crítico

La prevalencia de alucinaciones en modelos de lenguaje requiere el desarrollo de habilidades de verificación y pensamiento crítico en estudiantes. Esto presenta una oportunidad pedagógica para fortalecer competencias de evaluación de fuentes, fact-checking y análisis crítico de información.



3.4 Consideraciones Éticas

La implementación de IA en educación debe abordar preocupaciones sobre privacidad, sesgo algorítmico y dependencia tecnológica. Es fundamental desarrollar marcos éticos que guíen el uso responsable de estas tecnologías, priorizando el bienestar estudiantil y la equidad educativa.

4 CONCLUSIONES

Este glosario representa un esfuerzo por sistematizar el conocimiento terminológico necesario para la comprensión y adopción crítica de IA generativa en contextos educativos. La rápida evolución del campo requiere actualización continua de este marco conceptual, manteniendo un equilibrio entre precisión técnica y accesibilidad pedagógica.

La intersección de IA y educación presenta oportunidades sin precedentes para transformar procesos de enseñanza-aprendizaje, pero también desafíos significativos que requieren abordaje multidisciplinario. El dominio de este vocabulario técnico constituye un primer paso hacia la integración reflexiva y efectiva de estas tecnologías emergentes.

La inclusión de conceptos en evolución (marcados con “(evol)”) reflejan la naturaleza dinámica de este campo y alienta a los usuarios a involucrarse con debates en curso en lugar de aceptar definiciones como fijas. Este enfoque promueve el pensamiento crítico y la adaptabilidad—habilidades esenciales para navegar el panorama cambiante de la IA en educación.

Las futuras iteraciones de este glosario deberán incorporar desarrollos emergentes en áreas como modelos multimodales, agentes autónomos y sistemas de IA más especializados en dominios educativos específicos, manteniendo siempre la perspectiva pedagógica como criterio organizador principal.

5 APLICACIONES PRÁCTICAS Y GUÍA DE IMPLEMENTACIÓN

Por la oportunidad de sistematizar y compartir en diferentes escenarios académicos y de formación e investigación, el glosario resulta un ejercicio vital y en permanente evolución, que a su vez ha permitido también diseñar una experiencia de integración a procesos curriculares. En este apartado compartimos como recomendación la siguiente propuesta.

5.1 Para Cursos Universitarios de IA

Cursos Introdutorios (IA 101)

- Comenzar con términos fundamentales: Algoritmo, Aprendizaje automático, Inteligencia artificial
- Usar definiciones analógicas para construir comprensión intuitiva
- Enfocarse en aplicaciones educativas en lugar de implementación técnica
- Fomentar discusión crítica de Sesgo y Ética de la IA



Cursos Intermedios (Tecnología Educativa)

- Enfatizar la integración del marco TPACK con conceptos de IA
- Practicar *Prompt Engineering* a través de ejercicios prácticos
- Explorar posibilidades y limitaciones de Personalización
- Analizar estudios de caso de implementación de IA en varios contextos educativos

Cursos Avanzados (IA en Educación)

- Profundizar en Capacidades emergentes y sus implicaciones educativas
- Examinar requisitos de Explicabilidad para sistemas de IA educativa
- Diseñar currículos mejorados con IA considerando Multimodalidad
- Realizar investigación original sobre el impacto de la IA en resultados de aprendizaje

5.2 Para Desarrollo Profesional Docente

Nivel de Concienciación (2-4 horas)

- Introducción a IA generativa y LLM
- Experiencia práctica con herramientas de IA educativa
- Discusión de Sesgo y consideraciones éticas
- Habilidades básicas de *Prompt Engineering*

Nivel de Competencia (8-12 horas)

- Técnicas avanzadas de *Prompt Engineering*
- Estrategias de integración usando el marco TPACK
- Evaluación de la calidad del contenido generado por IA
- Desarrollo de planes de lección mejorados con IA

Nivel de Liderazgo (20+ horas)

- Desarrollo de políticas para el uso de IA en escuelas
- Diseño de formación para colegas
- Metodologías de investigación para evaluar el impacto de la IA
- Planificación estratégica para la adopción institucional de IA

5.3 Para Desarrollo de Políticas Educativas

Directrices Institucionales

- Usar principios de Ética de la IA para desarrollar políticas de uso



- Abordar la mitigación de Sesgo en la selección de herramientas de IA
- Establecer requisitos de Explicabilidad para aplicaciones de alto riesgo
- Crear marcos para evaluar la efectividad de herramientas de IA

Integración Curricular

- Mapear competencias de alfabetización en IA a través de niveles de grado
- Identificar aplicaciones de IA específicas por materia
- Desarrollar criterios de evaluación para aprendizaje mejorado con IA
- Planificar sistemas de formación y apoyo docente

Investigación y Evaluación

- Diseñar estudios usando terminología clave para consistencia
- Establecer métricas para medir el impacto de la IA en el aprendizaje
- Crear protocolos para monitoreo continuo de implementaciones de IA
- Desarrollar marcos para compartir mejores prácticas

5.4 Preguntas de Reflexión Crítica

Para Educadores:

1. ¿Cómo cambia entender la Semántica distribucional tu perspectiva sobre la comprensión del lenguaje de la IA?
2. ¿Cuáles son las implicaciones de las Capacidades emergentes para el diseño curricular?
3. ¿Cómo puedes equilibrar los beneficios de Personalización con las preocupaciones de privacidad?
4. ¿Qué papel debería jugar la Explicabilidad en las herramientas de IA educativa?

Para Formuladores de Políticas:

1. ¿Cómo impactan las definiciones evolutivas de IA los enfoques regulatorios?
2. ¿Qué marcos se necesitan para abordar el Sesgo sistemáticamente?
3. ¿Cómo pueden las instituciones prepararse para Capacidades emergentes impredecibles?
4. ¿Qué estructuras de gobernanza apoyan la implementación responsable de IA?

Para Investigadores:

1. ¿Cómo afectan las inconsistencias terminológicas la reproducibilidad de la investigación?
2. ¿Qué metodologías capturan mejor el impacto educativo de la IA?



3. ¿Cómo podemos estudiar los efectos de Personalización mientras protegemos la privacidad estudiantil?
4. ¿Qué enfoques interdisciplinarios avanzan la investigación en IA educativa?

5.5 Recomendaciones de Implementación

Fase 1: Construcción de Fundamentos (Meses 1-3)

- Establecer vocabulario común usando este glosario
- Realizar evaluación de necesidades para integración de IA
- Comenzar formación básica con conceptos centrales
- Formar grupos de trabajo interdisciplinarios

Fase 2: Programas Piloto (Meses 4-9)

- Implementar proyectos de integración de IA a pequeña escala
- Enfocarse en desarrollo de habilidades de *Prompt Engineering*
- Monitorear problemas de Sesgo y éticos
- Documentar lecciones aprendidas y mejores prácticas

Fase 3: Escalamiento y Evaluación (Meses 10-18)

- Expandir programas piloto exitosos
- Realizar evaluación formal de resultados de aprendizaje
- Refinar políticas basadas en experiencia
- Compartir resultados con la comunidad educativa más amplia

Fase 4: Mejora Continua (En curso)

- Revisión y actualización regular de terminología
- Desarrollo profesional continuo
- Colaboración en investigación y compartir conocimiento
- Adaptación a tecnologías de IA emergentes

5.6 Evaluación y Assessment

Evaluación de Conocimiento

- Pruebas pre/post usando terminología del glosario
- Asignaciones de aplicación práctica
- Ejercicios de enseñanza entre pares
- Ensayos reflexivos sobre experiencias de integración de IA



Evaluación de Competencias

- Demostraciones de habilidades de *Prompt Engineering*
- Rúbricas de evaluación de herramientas de IA
- Desarrollo de planes de lección incorporando IA
- Mediciones de resultados de aprendizaje estudiantil

Medición de Impacto

- Analíticas de aprendizaje de cursos mejorados con IA
- Métricas de compromiso y motivación estudiantil
- Tasas de confianza y adopción docente
- Seguimiento de logros académicos a largo plazo

REFERENCIAS

- Austin, J. L. (1962). *How to do things with words*. Oxford University Press.
- Bajtín, M. M. (1982). *Estética de la creación verbal*. Siglo XXI Editores.
- Baltrusaitis, T., Ahuja, C., & Morency, L. P. (2019). Multimodal machine learning: A survey and taxonomy. *IEEE transactions on pattern analysis and machine intelligence*, 41(2), 423-443.
- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and machine learning*. fairmlbook.org.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in neural information processing systems*, 33, 1877-1901.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., & Stein, C. (2009). *Introduction to algorithms*. MIT Press.
- Damasio, A. R. (1994). *Descartes' error: Emotion, reason, and the human brain*. Putnam.
- Engeström, Y. (1987). *Learning by expanding: An activity-theoretical approach to developmental research*. Orienta-Konsultit.
- Gardner, H. (1983). *Frames of mind: The theory of multiple intelligences*. Basic Books.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Harris, Z. S. (1954). Distributional structure. *Word*, 10(2-3), 146-162.
- Immordino-Yang, M. H., & Damasio, A. (2007). We feel, therefore we learn: The relevance of affective and social neuroscience to education. *Mind, Brain, and Education*, 1(1), 3-10.
- Jobin, A., Ienca, M., & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1(9), 389-399.
- Lave, J., & Wenger, E. (1991). *Situated learning: Legitimate peripheral participation*. Cambridge University Press.
- Lenci, A. (2018). Distributional models of word meaning. *Annual Review of Linguistics*, 4, 151-171.
- Liu, P., Yuan, W., Fu, J., Jiang, Z., Hayashi, H., & Neubig, G. (2023). Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing. *ACM Computing Surveys*, 55(9), 1-35.
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.



- Mishra, P., & Koehler, M. J. (2006). Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108(6), 1017-1054.
- Mitchell, M. (2019). *Artificial intelligence: A guide for thinking humans*. Farrar, Straus and Giroux.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?" Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, 1135-1144.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Salomon, G. (1993). *Distributed cognitions: Psychological and educational considerations*. Cambridge University Press.
- Searle, J. R. (1969). *Speech acts: An essay in the philosophy of language*. Cambridge University Press.
- Siemens, G. (2005). Connectivism: A learning theory for the digital age. *International Journal of Instructional Technology and Distance Learning*, 2(1), 3-10.
- Sweller, J. (1988). Cognitive load during problem solving: Effects on learning. *Cognitive science*, 12(2), 257-285.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.
- Wei, J., Tay, Y., Bommasani, R., Raffel, C., Zoph, B., Borgeaud, S., ... & Fedus, W. (2022). Emergent abilities of large language models. *arXiv preprint arXiv:2206.07682*.
- Xie, H., Chu, H. C., Hwang, G. J., & Wang, C. C. (2019). Trends and development in technology-enhanced adaptive/personalized learning: A systematic review of journal publications from 2007 to 2017. *Computers & Education*, 140, 103599.
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64-70.