

# Inteligencia Artificial Aplicada a la Educación: Logros, Tendencias y Perspectivas

Arana C.

## RESUMEN

En las últimas décadas la tecnología digital ha tomado una relevancia fundamental en nuestro devenir cotidiano. Dispositivos y artefactos de toda índole asisten y optimizan diversos procesos, tanto en nuestras actividades laborales como en la interacción con nuestros pares, la forma en que disfrutamos nuestro tiempo libre y hasta en cómo atendemos nuestra salud. La educación no escapa a este proceso vertiginoso y consistente de penetración de la tecnología, en particular la inteligencia artificial, en tan variados ámbitos. La inteligencia artificial procura que ordenadores, máquinas y otros artefactos emulen a la inteligencia humana, desarrollando así habilidades de aprendizaje y adaptabilidad que le permitan tomar decisiones autónomas. En este artículo se presentarán las aplicaciones de la inteligencia artificial a la educación, entre las que se destaca la presentación de contenidos, evaluaciones y recomendaciones pedagógicas adaptadas a las necesidades propias de cada estudiante, mejorando así la experiencia en el aula, la calidad general del aprendizaje y la efectividad de los diferentes procesos educativos e institucionales. A su vez se analizarán posibles líneas de investigación a futuro, como son, entre otras, el análisis de redes sociales (SNA) de estudiantes y la generación de contenido de soporte pedagógico.

## ABSTRACT

In recent decades, digital technology has taken on a fundamental relevance in our daily lives. Devices and artefacts of all kinds assist and optimise various processes, both in our work activities and in our interaction with our peers, the way we enjoy our free time and even in how we take care of our health. Education does not escape this vertiginous and consistent process of penetration of technology, in particular artificial intelligence, in so many different fields. Artificial intelligence seeks to enable computers, machines and other artefacts to emulate human intelligence, thus developing learning and adaptability skills that allow them to make autonomous decisions. This article will present the applications of artificial intelligence to education, including the presentation of content, assessments and pedagogical recommendations based on the needs of each student, thus improving their experience, the overall quality of learning and the effectiveness of the different educational and institutional processes. At the same time, possible lines of future research will be analysed, such as, among others, the analysis of students' social networks (SNA) and the generation of pedagogical support content.

## **PALABRAS CLAVE**

Educación, inteligencia artificial, pedagogía, aprendizaje automático, aprendizaje profundo.

## **KEY WORDS**

Education, artificial intelligence, pedagogy, machine learning, deep learning.

## INTRODUCCIÓN

Una importante cantidad de nuestras actividades diarias se ven influenciadas, o directamente se llevan a cabo, mediante diferentes dispositivos tecnológicos digitales y computacionales, muchos de ellos desarrollados en el pasado reciente. Esta irrefrenable participación de la digitalización en los más variados estamentos de la sociedad moderna también se ha evidenciado en la educación. Hoy en día es difícil imaginar un entorno educativo, desde los más iniciales, en los que no haya alguna participación o interacción con algún dispositivo informático que maneje o procese información digital.

Ejemplo emblemático de la penetración de los contenidos digitalizados en la educación son los cursos en línea, masivos y abiertos, o MOOC, por sus siglas en inglés de *Massive Online Open Courses*. De su nombre podemos inferir que se trata de cursos abiertos accesibles de forma virtual y que, en la mayoría de los casos, no posee un cupo de estudiantes predeterminado. Además del material de soporte un curso tradicional, como son los apuntes de cátedra, las clases teórico/prácticas (en este caso pre-grabadas) y las guías de ejercitación de los contenidos vertidos en clase, los MOOC incluyen foros de usuarios que ayudan a construir una comunidad de debate, análisis e interacción entre estudiantes, profesores y asistentes.

### **El surgimiento de la Inteligencia Artificial**

Las computadoras personales, surgidas a fines de década del 70 y principios de los 80, permitieron que este tipo de dispositivos de gran capacidad de cómputo fuera accesible a particulares y no sólo a grandes empresas o instituciones gubernamentales. En poco tiempo fue tornándose cada vez más común la presencia y la utilización de computadoras en una enorme cantidad de actividades y procesos de la más variada índole [1]. La computación comienza a desempeñar un rol de asistencia y automatización de diversos procesos en diferentes áreas y aplicaciones, siendo ejemplo de ello los sistemas de asistencia computarizada en diseño o manufactura (CAD y CAM, por sus siglas en inglés de *Computer Aided Design* y *Computer Aided Manufacturing* respectivamente). Análogo proceso de penetración de la computación se dio en educación con el surgimiento de los sistemas de asistencia computarizada a la enseñanza y a la instrucción CAIL, por sus siglas en inglés de *Computer Aided Instruction and Learning* [2]. A su vez, los sucesivos desarrollos y avances tecnológicos como las redes informáticas, la Internet, el software de toda índole y el hardware especializado, contribuyeron a la utilización más intensiva y frecuente de los sistemas computacionales en los más variados ámbitos educativos. En el plano más científico se gestaba una fusión entre la Ciencia de la Computación (disciplina científica que trata sobre la teoría, el análisis, el diseño, y la implementación de operaciones computacionales y algorítmicas en pos de optimizar los procesos de adquisición, representación, procesamiento, almacenamiento, comunicación y acceso a la información), con lo más sofisticado y avanzado de las matemáticas, en especial de la estadística y del análisis numérico, que allanó el terreno para el surgimiento de la inteligencia artificial.

La Inteligencia Artificial (que de aquí denominaremos de forma alternativa por sus siglas, IA) , según Coppin[3], es “la capacidad de las máquinas para adaptarse a nuevas situaciones, hacer frente a situaciones emergentes, resolver problemas, responder a preguntas, elaborar planes y realizar funciones que requieren un cierto nivel de inteligencia, típicamente característico de los seres humanos”. En otra definición, Whitby [4] describió a la inteligencia artificial como “el estudio del comportamiento de la inteligencia en los seres humanos, los animales y las máquinas y el esfuerzo por diseñar dicho comportamiento en un artefacto, como los ordenadores y las tecnologías relacionadas con la informática”. Sin duda a partir de estas definiciones podríamos afirmar que la IA es el punto de consumación de lo más acabado de la tecnología moderna, siendo sus aspiraciones, y varios de sus logros, de una importancia sumamente notoria en la historia de la ciencia, en especial de la computación y de la teoría de la información. Al ser su característica fundamental la adaptación a su entorno y, a partir de este, la adopción de comportamientos inteligentes, fue natural su paulatina y constante incorporación a los diferentes entornos y estratos educativos.

El uso de la IA en la educación ha tenido un gran impacto, incluyendo el aprendizaje global, el aprendizaje personalizado, el desarrollo de contenido adaptativo y la mejora de la eficacia y la eficiencia en la administración de la educación, entre otros [5]. El desarrollo de la IA como disciplina científica vive un momento de apogeo por lo que se augura que su influencia en la educación será cada vez será mayor. Del mismo modo, la educación basada en la web y en línea, tal y como se ha enumerado en diferentes estudios, ha pasado de limitarse a disponer de materiales en línea o en la web para que los estudiantes simplemente los descarguen, estudien y realicen tareas para aprobar (como es el caso de los MOOCS), a incluir sistemas inteligentes y adaptativos que relevan, aprenden y se retroalimentan del comportamiento del instructor y del estudiante para, a partir de ellos, generar modelos y algoritmos con el fin de enriquecer la experiencia educativa [5], [6], [7], [8].

## **OBJETIVOS**

Este artículo busca evaluar la vinculación en los diferentes estratos y procesos educativos de las diferentes tecnologías y disciplinas que componen el paradigma de la Inteligencia Artificial. Más concretamente, el estudio tratará de evaluar cómo la IA ha afectado a la enseñanza, el aprendizaje y a la administración y gestión de la educación. Se determinará, mediante un sistemático análisis de la literatura científica asociada al tema, la influencia y el grado de penetración de Inteligencia Artificial en la educación, y cómo mediante su asistencia y la aplicación de sus técnicas se ha incrementado la eficacia y la eficiencia de la enseñanza, mejorado y optimizando los procesos de aprendizaje, asimilación, evaluación, seguimiento y detección temprana de comportamientos anómalos.

Este estudio beneficiará a diversos actores del sector educativo en su conjunto. Contribuirá al creciente estudio y desarrollo de conocimientos, teorías, análisis y estrategias educativas a partir de las probadas ventajas que ofrecen los diferentes desarrollos de la Inteligencia Artificial aplicada a la educación. Beneficiará a profesionales de la educación, tanto a os

involucrados en los diseños curriculares y a los que ejercen la docencia en el aula, como también a administradores, dirigentes de instituciones educativas, gestores culturales y gubernamentales, que contarán con resultados, conclusiones y recomendaciones basados en estudios que, al haber sido obtenidos mediante una rigurosa metodología científica, nos aseguran su solidez y representatividad.

## **METODOLOGÍA**

### **Modelos interactivos y sistemas de tutoría inteligentes**

Una de las responsabilidades más importantes del profesor o instructor es la de dar una devolución apropiada y específica al estudiante [9]. Este simple y fundamental acontecimiento propio del aula física tradicional puede ser sumamente complicado de consumarse si es que la clase se dicta frente a un alumnado numeroso, máxime si ésta se configura de forma virtual, como es el caso de los MOOCs ya vistos. Es por ello que muchas instituciones educativas, especialmente universidades, implementan entornos de aprendizaje interactivos ILE, por sus siglas en inglés de *Interactive Learning Environments*. En estos el fin que se persigue es mejorar la calidad de la enseñanza mediante la retroalimentación y la tutoría personalizada. ILE es un término complejo, que exige que sus modelos sean una combinación de técnicas de e-learning, en los que a los sistemas de gestión del aprendizaje (LMS por sus siglas en inglés de *Learning Management Systems*) se le adicionan funcionalidades propias de un modelo interactivo. El objetivo, y la idea rectora sobre la que se articulan los entornos de aprendizaje interactivos, es la comprensión profunda de los conceptos y contenidos curriculares por parte de los estudiantes, tomando especial consideración de su experiencia personal y de la asimilación de los conocimientos presentados, para a partir de ellas realizar las interacciones apropiadas que mejoren y optimicen el proceso de aprendizaje.

Chassignol, en su completo trabajo de revisión de publicaciones científicas del tema [5], presenta los siguientes cuatro componentes fundamentales de los modelos de aprendizaje interactivo:

- Contenido
- Métodos de enseñanza
- Evaluación
- Comunicación.

*Contenido:* se refiere al conjunto de conocimientos que los profesores enseñan y que se espera que los estudiantes aprendan en una determinada asignatura o área temática. Se incluye bajo este componente tanto el contenido educativo como su personalización, que

como veremos será una de las áreas fundamentales de la aplicación de las tecnologías basadas en IA, en particular las relativas a los procesos de decisión autónoma.

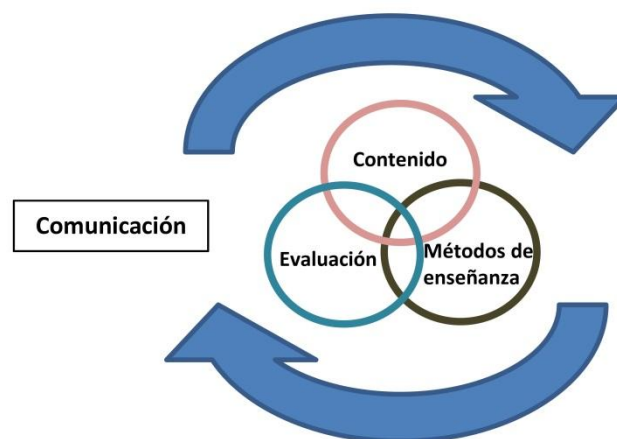
*Métodos de enseñanza:* representan los diferentes principios y procedimientos didácticos utilizados por los profesores para transmitir el conocimiento correspondiente y asegurarse la correcta asimilación por parte de los estudiantes.

*Evaluación:* se refiere a la amplia variedad de métodos o herramientas que los educadores utilizan para evaluar, medir y documentar la preparación académica, el progreso del aprendizaje, la adquisición de habilidades y/o las necesidades educativas de los estudiantes.

*Comunicación:* se refiere a la interacción entre estudiantes y profesores, en lo referente a consultas, ejercitación, corrección, evaluación, etc.

En la Figura 1 podemos apreciar la interacción existente entre estos componentes.

**Figura N° 1:** Modelo Interactivo de Aprendizaje



Fuente: Adaptación de Chassignol et al. [5]

### a) Sistemas de Tutoría Inteligente

A los modelos de aprendizaje interactivos ILE a los que se le aplican técnicas de IA se los denomina Sistema De Tutoría Inteligente ITS, por sus siglas en inglés de Intelligent Tutoring Systems. Existe un importante consenso en la comunidad científico-educativa que indica y afirma que el uso de sistemas de tutoría inteligente ITS redundará en un mayor rendimiento en la asimilación y comprensión por parte de los estudiantes comparado al que se consigue utilizando los métodos tradicionales de aula basados en el estudio de materiales impresos [10].

Variadas disciplinas científicas y campos del conocimiento han aprovechado los beneficios de la implementación de sistemas educativos montado sobre las técnicas de ITS. En la bibliografía podemos encontrar su aplicación en variados ámbitos académicos

como Física [11], Matemática [12] [13], Lengua y Literatura [14] [15], Informática [9] [16] y Medicina [17], entre otras. Mahmoud et al. [14] describen muchos ejemplos de diferentes sistemas de tutoría, como The AutoTutor [18], Why2-Atlas [15], Beetle II System [11][19]etc. La Tabla 1 presenta algunos modelos basados en ITS, las disciplinas en los que se aplican y sus estudiantes destinatarios.

**Tabla N°1:** Modelos basados en ITS.

ITS	Disciplina	Destinatario
ActiveMath	Matemáticas	Secundarios
Beetle II System	Programación	Secundarios
EER-Tutor	Informática	Universitarios
MATHia	Matemáticas	Secundarios
The AutoTutor	Informática	Secundarios
Why2 Atlas	Física	Universitarios
COMET	Medicina	Universitarios
VIPER	Medicina	Universitarios

Fuente: Adaptación de Chassignol et al. [5]

Los sistemas de tutoría inteligentes proporcionan instrucción y retroalimentación oportunas y personalizadas tanto para los estudiantes como para los instructores. Están diseñados para mejorar el valor y la eficiencia del aprendizaje basándose en múltiples tecnologías informáticas, especialmente la inteligencia computacional, los sistemas expertos (basados en una serie de reglas concatenadas , desarrolladas en base al conocimiento aportado por especialistas en la disciplina o saber) y el aprendizaje estadístico .

## **b) Modelos de Sistema de Aprendizaje y Tutoría Inteligente**

El modelo general de sistema de aprendizaje y tutoría inteligente, propuesto por primera vez por Peter Brusilovsky, profesor e investigador de la Escuela de Ciencias de la Información de la Universidad de Pittsburgh, se divide en dos módulos fundamentales: el módulo de sistema (que incluye el modelo del estudiante, el modelo de enseñanza, el modelo de conocimiento y el modelo de interfaz) y el motor adaptativo inteligente o de tecnologías inteligentes [20].

*Modelo del estudiante:* Durante el proceso de aprendizaje se generan en tiempo real, y en simultáneo, datos multidimensionales sobre el comportamiento de los estudiantes. En el sistema de aprendizaje adaptativo inteligente, el modelo del estudiante es fundamental para mejorar la capacidad de aprendizaje. El primer nivel del modelo de aprendizaje se centra en el pensamiento y la capacidad de los estudiantes y se utiliza para evaluar sus habilidades de aprendizaje. El segundo nivel del modelo de estudiante mapea los puntos



de conocimiento, para dar una imagen completa del dominio de los conocimientos de los estudiantes [21]. El modelado de los datos del estudiante -que refleja las relaciones entre los resultados del aprendizaje y una serie de variables que incluyen los contenidos y el material didáctico, los recursos de aprendizaje y los comportamientos de enseñanza- puede utilizarse para predecir el nivel de asimilación de los conceptos por parte de los estudiantes. Este tipo de análisis inteligentes proporcionará a los estudiantes y a los profesores recursos, actividades y hasta planes de estudio, adaptados a sus necesidades y a los logros de los estudiantes. Contando con más información objetiva proporcionada por el procesamiento de estos datos, docentes y profesores podrán optimizar su planificación educativa, ajustando y administrando los contenidos y los planes educativos según el estado de aprendizaje de los estudiantes.

*Modelo del campo de conocimiento:* El modelo de campo de conocimientos describe la estructura de los conocimientos y establece un mapa conceptual que incluye contenidos y material de aprendizaje detallado, conocimientos especializados, errores regularmente cometidos por los estudiantes, y reglas para solucionar fallas de conceptos o confusiones [21]. Es mediante esta configuración y planificación que luego se podrán realizar todo tipo de constataciones y mediciones del grado de avance académico y pedagógico de los estudiantes, que son la esencia del modelo de enseñanza.

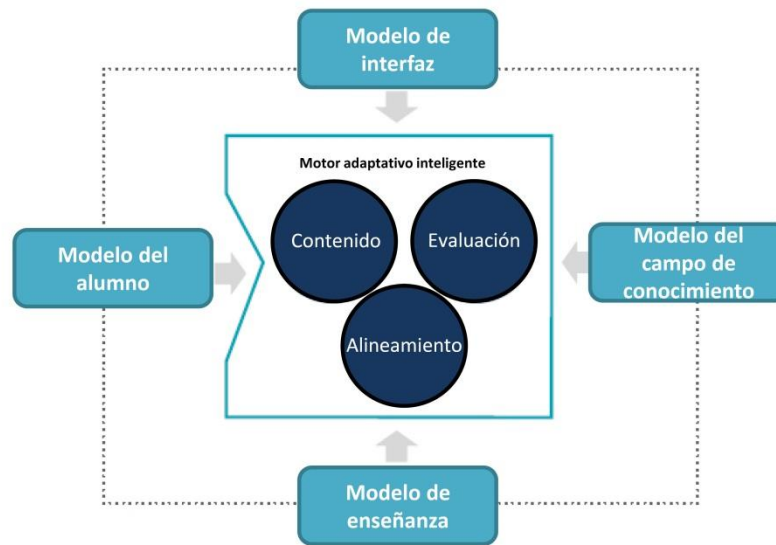
*Modelo de enseñanza:* El modelo de enseñanza define las reglas sobre cómo obtener acceso a cada campo de conocimiento basándose en la información proporcionada por el modelo del estudiante. Combinando el modelo de campo de conocimiento y el modelo de estudiante, el modelo de enseñanza permite a los profesores determinar qué estrategias y acciones de instrucción deben llevar a cabo. Los ITS deben estar siempre preparados para decidir "qué hacer a continuación", lo que viene determinado por el modelo de enseñanza.

*Modelo de interfaz:* La interfaz de usuario explica la actuación de los estudiantes a través de múltiples mecanismos de entrada (voz, teclados y mouse) y proporciona la salida (textos, video, figuras, dibujos) a través de diferentes medios. Además de la función tradicional de la interfaz hombre-máquina, algunos sistemas también tienen otras funciones como la interacción mediante lenguaje natural, reconocimiento del habla y detección de las emociones de los estudiantes.

*Motor adaptativo inteligente:* El motor adaptativo inteligente recoge información sobre las características de los estudiantes y los objetos de conocimiento a partir de la base de datos de modelos de estudiantes y la base de datos de modelos de campos de conocimiento y de enseñanza. A continuación veremos con más detalle las principales técnicas y tipos de modelos computacionales y algorítmicos utilizados para esta tarea (considerada como esencia y fundamento de los ITS) que es la responsable de dotar a estos sistemas educativos de las características de adaptabilidad y criterio propio de un sistema inteligente.



**Figura 2:** Modelo de referencia y componentes de un Sistema Adaptativo Inteligente



Fuente: Adaptación de Deloitte [21]

### Tecnologías utilizadas en el motor adaptativo inteligente

Las disciplinas comprendidas dentro del universo de la Inteligencia artificial más utilizadas como asistentes de sistemas educativos son el Aprendizaje Automático (*machine learning*) y el Aprendizaje profundo o *Deep Learning*. A continuación se presentarán los detalles y las características de cada uno de ellas, para luego detallar las aplicaciones en el entorno de este estudio.

#### a) Aprendizaje automático:

La disciplina especializada de la estadística tradicional encargada de encontrar patrones a partir de un conjunto de datos se denomina "Aprendizaje Estadístico". Veamos la definición que nos dan Hastie et.al en "Elements of Statistical Learning", la obra fundamental de la disciplina:[22] " El aprendizaje estadístico trata sobre el aprendizaje a partir de los datos. En un escenario típico, tenemos una medida de resultado, normalmente cuantitativa o categórica, que deseamos predecir basándonos en un conjunto de características. Disponemos de un conjunto de datos de entrenamiento, en el que observamos el resultado y las medidas de las características para un conjunto de objetos. Con estos datos construimos un modelo predictivo que nos permitirá predecir el resultado para nuevos objetos no vistos. Un buen modelo es aquel que predice con exactitud dicho resultado." Luego cierra la presentación indicando "La ciencia del aprendizaje desempeña un papel fundamental en los campos de la estadística, la minería de datos y la inteligencia artificial, y se cruza con áreas de la ingeniería y otras disciplinas." Aquí claramente podemos ver la inseparable relación entre la estadística y la inteligencia artificial, y como a partir de ella surgen originalmente las disciplinas de data mining y de aprendizaje automático, ambas con aplicaciones similares en la práctica.

Ahora revisaremos algunas definiciones específicas del aprendizaje automático, la disciplina estadístico-computacional que en la actualidad sintetiza los desarrollos y las tendencias del aprendizaje estadístico y de la minería de datos. Bishop, en su obra fundacional “*Pattern Recognition and Machine Learning*” [23], define al aprendizaje automático como “un conjunto de métodos que pueden detectar automáticamente patrones en los datos y, a continuación, utilizar los patrones descubiertos para predecir datos futuros, o para realizar otros tipos de toma de decisiones en condiciones de incertidumbre”. En una definición un poco más general, Arthur Samuel [24], nos dice que “el aprendizaje automático es el campo de estudio que da a los ordenadores la capacidad de aprender sin estar explícitamente programados”. Y la excelente y concisa definición de la obra clásica de Mitchell “*Machine Learning*” [25], más orientada a la ciencia de la computación y a la ingeniería: “se dice que un programa informático aprende de la experiencia  $E$  con respecto a una tarea  $T$  y una medida de rendimiento  $P$ , si su rendimiento en  $T$ , medido por  $P$ , mejora con la experiencia  $E$ ”.

### ***1. Tipos de Aprendizaje automático***

El aprendizaje automático suele dividirse en dos tipos principales, aprendizaje supervisado y no supervisado. En el enfoque de aprendizaje supervisado o predictivo el objetivo es aprender un mapeo de las entradas  $x$  a las salidas  $y$ , dado un conjunto de observaciones de ambas. A estos datos utilizados para el aprendizaje, se lo denomina conjunto, o *set*, de entrenamiento. En el caso más sencillo, cada entrada de entrenamiento  $x_i$  (el subíndice  $i$  indica que se corresponde con una componente genérica del conjunto de entrenamiento) es un vector cuyos elementos son una cantidad definida de características, atributos o covariables, cuyos valores son conocidos de antemano. Sin embargo, en general,  $x_i$  puede ser un objeto estructurado complejo, como una imagen, una frase, un mensaje de correo electrónico, una serie temporal, una estructura molecular, un gráfico, etc. Del mismo modo, la variable de salida o respuesta  $y$  puede ser, en principio, de cualquier tipo, pero en la mayoría de los métodos del aprendizaje automático se asume que  $y_i$  es una variable categórica o nominal, o que es un variable de tipo real. Cuando  $y_i$  es de tipo categórico, el modelo se denomina de Clasificación o de Reconocimiento de Patrones, y cuando  $y_i$  es de valor real, de Regresión.

El segundo tipo principal de aprendizaje automático es el enfoque de aprendizaje no supervisado o descriptivo. En este caso, sólo se dan entradas  $x$  y el objetivo es encontrar patrones informativos en los datos. Esto se denomina Descubrimiento del Conocimiento. Se trata de un problema mucho menos definido, ya que no se nos aclara ni indica qué tipo de patrones hay que buscar, y no hay una métrica de error para medir la performance del modelo (a diferencia del aprendizaje supervisado, en el que podemos comparar nuestra predicción de la variable objetivo  $y$  para una  $x_i$  dada con el valor observado de  $y_i$  presente en le *set* de entrenamiento).

### ***2. Aplicaciones en educación***

Una de las aplicaciones fundamentales del aprendizaje automático es la recomendación del contenido más adecuado para cada estudiante en función de sus preferencias, hábitos

de aprendizaje y estilo. El sistema educativo montado sobre modelos de aprendizaje automático registrará las preferencias de cada estudiante y realizará de manera autónoma las recomendaciones pertinentes. Basándose en el estado del aprendizaje y los objetivos curriculares, el sistema proporcionará automáticamente las lecciones y las actividades que mejor se adapten a las necesidades del estudiante, con el nivel de dificultad adecuado y en la secuencia correcta, para que éste no pierda la confianza ni se sienta frustrado, o desincentivado, por haberse fijado objetivos demasiado altos o demasiado bajos, respectivamente.

Los modelos de aprendizaje automático también pueden utilizarse al análisis de la educación y el aprendizaje visto desde un enfoque pedagógico general. A estas áreas de aplicación se la denomina “Analítica del Aprendizaje”. Estos modelos miden y analizan el proceso y las actividades de aprendizaje, recopilando el todo tipo de datos a partir de la experiencia de los estudiantes incluido el tiempo de aprendizaje, la duración y el rendimiento de las pruebas, seguido de un análisis de estos datos que permitirán el desarrollo modelos de aprendizaje personalizados. Estos modelos a su vez predicen y supervisan las puntuaciones de los estudiantes en los exámenes, que permiten tomar medidas y cursos de acción e intervención pertinentes para su mejor preparación y la formulación óptima de las evaluaciones. La analítica del aprendizaje ayuda a desarrollar objetivos de aprendizaje personalizados, con incentivos adaptados a cada estudiante, a su vez proporcionando a los profesores datos detallados de estos, como el tiempo que han invertido en cada actividad y su nivel de comprensión, ayudando así al sistema, y a los propios profesores, a mejorar los métodos de enseñanza.

#### **b) Aprendizaje profundo:**

Estos modelos están basados en las redes neuronales artificiales, estructura de grafos computaciones que fueron inspirados en las neuronas y las sinapsis de nuestros cerebros. Las redes neuronales permiten generar niveles de representaciones cada vez más compleja a partir de una estructura de capas apiladas en forma sucesiva o recurrente. Si las redes poseen una importante cantidad de capas apiladas se las denomina redes profundas, siendo esta la razón por la que al proceso de entrenamiento (en que se aprenden estas representaciones sofisticadas a partir de otras más simples) se lo denomine “Aprendizaje Profundo” o *Deep Learning*.

Los modelos de *Deep Learning*, entre muchas otras aplicaciones en la educación, nos ayudan a trazar desarrollar el recorrido estudio óptimo para que los estudiantes maximicen la eficiencia del aprendizaje. Este modelo recomienda la siguiente lección adecuada en función de los objetivos de aprendizaje preestablecidos y su estado actual de aprendizaje, y ajusta las lecciones en tiempo real en función de la evolución de su comprensión de los conocimientos. Después de recibir los diferentes tipos de datos de los estudiantes generados a partir de los contenidos de aprendizaje que se han presentado en clase, el sistema desarrollará perfiles de los estudiantes que contemplen sus hábitos, intereses y métodos de aprendizaje, al tiempo que optimiza automáticamente su lógica de presentación y exposición.

## RESULTADOS Y DISCUSIÓN

### Aplicaciones fundamentales de la inteligencia artificial en educación

A partir los ya mencionados y analizados Sistemas de Administración de la Educación (LMS) y de Tutoría Inteligente (ITS), surge la disciplina que trata sobre la integración de los ITS con el aprendizaje automático, denominada Minería de Datos Educativo, o EDM (por sus siglas en inglés de *Educational Data Mining*). Su definición formal es [26]: “La EDM se ocupa de desarrollar, investigar y aplicar el aprendizaje automático, la minería de datos y los métodos estadísticos para detectar patrones en grandes colecciones de datos educativos que de otro modo serían imposibles de analizar”

Un exhaustivo análisis de diferentes fuentes y artículos de EDM -en los que se analiza el impacto de la IA en la educación, su grado de penetración y utilización- nos permite clasificar a la amplia gama de aplicaciones de la IA en las cuatro categorías fundamentales que se presentan a continuación.

#### a) Evaluación y calificación

Diferentes enfoques han afrontado el reto de proporcionar herramientas adecuadas y productivas para ayudar a los docentes en el proceso de calificación y evaluación. A éstas se las puede clasificar, a grandes rasgos, en dos subcategorías: Calificación Automática de Ensayos (AES por sus siglas en inglés de *Automated Essay Scoring*) y Calificación Automática de Respuestas cortas (ASAG por sus siglas en inglés de *Automatic Short Answer Grading*). Los modelos de AES se utilizan para calificar la escritura de textos y ensayos a partir de una cierta consigna. Para ello se utilizan técnicas propias del Procesamiento Natural del Lenguaje (NLP por sus siglas en inglés de *Natural Language Processing*, disciplina especializada en la formulación de mecanismos algorítmicos y computacionales para formalizar y analizar los componentes y el contenido de las estructuras propias de los lenguajes naturales, siendo éstos los utilizados por los hombres con fines comunicacionales) y métodos de aprendizaje automático para calificar automáticamente las respuestas en lenguaje natural de los estudiantes. Los modelos AES han permitido conseguir avances significativos en esta área, en la que tradicionalmente para la comprensión de los textos era necesaria la intercesión de un tutor humano [27]. En otro desarrollo [28] se aplicó un modelo de DL para identificar la mejor representación de atributos para encontrar el patrón que relacionara la calidad de un ensayo y la puntuación asignada. Los resultados mostraron una mejora con respecto a otros enfoques que requieren mucho más pre-procesamiento e ingeniería de atributos.

Los sistemas ASAG clasifican automáticamente las respuestas de los estudiantes como correctas o erróneas, basándose en un corpus observado (dataset de entrenamiento) de respuestas. En [29] los autores tomaron atributos que asociaban preguntas, sus correspondientes respuestas y ciertas características del modelo del estudiante, tanto individualmente como combinadas, para luego integrarlas en diferentes modelos de aprendizaje automático. Los modelos de *Deep Learning* obtuvieron el mejor rendimiento en sus experimentos. Akram [30] introdujo un marco de análisis temporal que analizaba

las estrategias de resolución de problemas de los estudiantes en un entorno de aprendizaje basado en teoría de juegos. En [31] los autores exploraron cómo una herramienta de análisis de texto basada en la teoría de la información podía ayudar a evaluar la forma en que los estudiantes razonaban sobre diferentes tópicos. Por último, [32] propuso un método de DL para ayudar a estimar si los estudiantes conseguían dominar ciertas habilidades mediante un conjunto de experimentos utilizando para ellos pruebas del tipo A/B.

## **b) Detección de comportamiento no deseados y retención de los estudiantes**

La identificación temprana de los estudiantes con mayor propensión al abandono (sea de un curso/materia o de un programa académico) permite que las instituciones educativas puedan poner en práctica una acción previamente planificada tendiente a la retención del educando, cuyas características se amolde a las particularidades del caso específico. La retención de estudiantes es una parte esencial de muchos subsistemas educativos, que van desde la matriculación a la graduación, impactando y repercutiendo en muy variadas métricas que las universidades e instituciones controlan con particular recelo: reputación, ranking, tasas de graduación, nivel de recomendación, donaciones, etc. La retención de estudiantes se ha convertido en uno de los aspectos más importantes para la gestión de las instituciones de enseñanza superior en muchos países desarrollados. Hay varios estudios en los que se detalla la implementación de modelos especializados en la predicción y en el análisis pormenorizado de las razones por las que disminuye el número de estudiantes en una institución educativa [33] [34] [35] [36] [37] [38].

Otras de las áreas en la que se utilizan los modelos de aprendizaje automático, y en especial los de *Deep Learning*, es la detección de comportamientos anómalos, en especial los asociados al compromiso de los estudiantes con el estudio y con la propuesta académica de la que están participando. Como ejemplo de ello, en [39] se observó a los estudiantes a través de una transmisión en directo que incluía el filmación de sus rostros, el análisis de sus miradas superpuestas en tiempo real sobre una captura de vídeo de la pantalla y sus voces grabadas a través de un micrófono de auriculares. Los resultados empíricos sugieren que los modelos de *Deep Learning* que utilizan registros de acción visual y facial logran la mayor precisión predictiva. En [40] se asumió que si los vídeos educativos no son atractivos, los estudiantes tienden a perder interés en el contenido del curso. Los autores combinaron información sonora y visual para predecir el grado de atracción y vivacidad de un vídeo utilizando DL. Los resultados demostraron una mejora significativa en comparación con los métodos tradicionales. El trabajo de [41] se centró en los movimientos de la mirada y la postura para determinar la intensidad del compromiso mientras se ven vídeos de cursos educativos en línea. Los autores desarrollaron un entorno montado en técnicas de DL que aceptaba múltiples canales de entrada (métricas estadísticas, descriptores faciales y atributos relacionados a la acción) y evaluaron el rendimiento de diferentes modalidades utilizando este entorno. Los resultados experimentales demostraron la eficacia del método propuesto. Otro trabajo que aborda el compromiso de los estudiantes fue desarrollado por [42]. Identificaron a los estudiantes desconectados o desincentivados, ayudando así a los profesores a reconocer mejor si éstos están prestando atención al contenido o a la actividad propuesta en clase. Se desarrolló un



prototipo de sistema basado en DL para el seguimiento automatizado de la actividad ocular, que estimaba para cada estudiante en el aula hacia dónde estaba apuntando su mirada. El método propuesto podía estimar la ubicación del objetivo de la mirada de cada persona en la imagen con una precisión sustancialmente mejor que el azar y superior a otros métodos básicos tradicionales.

### **c) Predicción del rendimiento de los estudiantes**

Probablemente la predicción del rendimiento y de la performance académica de un estudiante sea una de las principales áreas de aplicación del aprendizaje automático en la educación, quedando claramente demostrado por la cantidad de artículos científicos publicados a la fecha que tratan sobre este asunto. Una de las áreas más desarrolladas es la denominada Seguimiento del Conocimiento (*Knowledge Tracing*). Como ejemplo de esto tomemos la aplicación de del Clustering Recursivo. En [43] los autores aplican esta técnica del aprendizaje no supervisado para segmentar a los estudiantes de un curso de programación en grupos basados en su rendimiento en los cursos de ingreso. Los estudiantes que forman parte de los grupos más bajos serán considerados con especial atención, generándose un plan pedagógico específico cuyo objetivo es reducir la propensión de esos estudiantes a desaprobado el curso. En otro estudio de esta categoría los autores han propuesto un nuevo modelo para clasificar a los estudiantes en tres categorías para determinar sus capacidades de aprendizaje y ayudarles a mejorar sus técnicas de estudio. Han optado por un enfoque de aprendizaje automático de última generación para clasificar a los estudiantes a partir de la selección de características destacadas de su actividad en su campo académico. Mediante este enfoque han podido clasificar a los estudiantes en grupos de riesgo en rangos altos, medios y bajos [44].

En [45], los autores presentaron un clasificador de DL para predecir el rendimiento de los estudiantes. El sistema aprendió automáticamente múltiples niveles de representación y permitió generar clústeres con estudiantes de diferentes aptitudes, permitiendo así una mejor estimación del posible resultado de las evaluaciones posteriores. En esta línea, [46] propuso un método para predecir las calificaciones finales de los estudiantes aplicando DL a los datos almacenados de un sistema educativo del tipo LMS. Los datos de registro representaban las actividades de aprendizaje de los estudiantes que utilizaban los sistemas de portafolios electrónicos (*e-portfolios*) y de libros electrónicos (*e-books*), ambos partes de la plataforma de material de apoyo al LMS. Por último, [47], [48] reformularon el problema de la predicción del rendimiento de los estudiantes como un problema de predicción de eventos secuenciales y propusieron un algoritmo de DL llamado GritNet.

### **d) Evaluación y Generación de Recomendaciones**

La evaluación basada en el aprendizaje automático proporciona información de manera constante a los profesores, estudiantes y padres sobre el proceso de aprendizaje, el apoyo que el estudiante necesita, su progreso y su relación con los objetivos de aprendizaje fijados. Como ejemplo de la aplicación de técnicas de aprendizaje automático clásico, tenemos el ejemplo de [49]. Además de las técnicas habituales, que incluyen presentaciones apoyadas por diapositivas y ejercicios, utilizaron animaciones que se

basaban en ejemplos demostrativos cuidadosamente seleccionados y sus soluciones asociadas desarrolladas paso a paso. Para comprobar los conocimientos de los estudiantes prepararon un cuestionario que recogía todo el proceso de construcción de una prueba lógica. Un estudiante construía una prueba y luego respondía a las preguntas del cuestionario. Describieron el diseño del cuestionario y discutieron sus desventajas. Al final, aplicaron algoritmos de aprendizaje automático supervisado para realizar una evaluación automática de la corrección de las evaluaciones.

Como ejemplos de aplicación técnicas más avanzadas de DL tenemos un sistema de recomendación presentado en [50]. Este sistema híbrido (llamado LeCoRe) realiza recomendaciones de contenido y ejercitación basados en las preferencias implícitas y explícitas analizadas en los registros de actividad de los estudiantes. En la fase de aprendizaje de LeCoRe se aplicaron por separado algoritmos de filtrado colaborativo tradicionales y algoritmos de DL basados en el contenido. Los autores concluyeron que el marco propuesto era capaz de modelar con éxito las preferencias del estudiante. Otro trabajo [51] se centró en el problema muy poco investigado de la planificación curricular para los estudiantes, proporcionando un enfoque novedoso para este ámbito basado en dos componentes: un enfoque de DL para las recomendaciones secuenciales y un recomendador para proporcionar un camino personalizado hasta la finalización del módulo educativo utilizando parámetros de secuencia, restricción y contexto.

### **Perspectivas y trabajo a futuro**

Luego de relevar y analizar los diferentes sistemas y modelos en los que se aplica la IA a la educación, tanto mediante el uso de las técnicas del aprendizaje automático clásico como de las redes neuronales artificiales y el *Deep Learning*, ahora presentaremos el panorama a futuro. En su artículo de investigación Hernández-Blanco et al. [52], luego de una exhaustiva y detallada revisión de artículos científicos presentados en diferentes revistas y congresos de *Educational Data Mining*, nos presenta las áreas que no han sido suficientemente explotadas, por ende siendo susceptibles de ser las destinatarias de futuras líneas de investigación. Las más relevantes son:

- **Análisis de redes sociales.** el objetivo es obtener un modelo de estudiante que contemple las diferentes relaciones posibles entre las estudiantes, vistas desde la óptica de la teoría clásica de redes sociales, pudiendo establecer relaciones y conexiones de diferente grados de afinidad en busca de patrones de toda índole. Por ejemplo Rallo et al [53] utilizaron la minería de datos y l análisis de redes sociales para modelar la dinámica y la estructura de comunidades educativas en línea.
- **Creación de material didáctico.** el objetivo es ayudar a los educadores a crear y desarrollar material didáctico que se adapte a las particularidades y alcances de las disciplinas y saberes a transmitir, utilizando para ello las funcionalidades y prestaciones de la IA, en particular las redes neuronales generativas. Estas arquitecturas especializadas de Deep Learning -basadas en la interacción de dos redes



neuronales diferentes, una generadora y otra discriminativa- se especializan en la generación de datos sintéticos a partir de un corpus de observaciones.

- **Desarrollo de mapas conceptuales y curriculares.** Los mapas conceptuales son herramientas gráficas para organizar y representar el conocimiento. En esta categoría de aplicaciones el objetivo es desarrollar mapas conceptuales de diversos aspectos para ayudar a los educadores a definir y organizar los diferentes componentes del proceso educativo. Algunos ejemplos de mapas conceptuales son: la jerarquía de los temas en el material del curso, las relaciones entre las habilidades y los ítems de los exámenes, la correlación entre los ítems de los exámenes y los componentes del conocimiento, etc. Agrawal et al. [54] presentan un navegador para estudiar libros de texto electrónicos que va creando referencias cruzadas que relacionan los conceptos que los estudiantes van leyendo, permitiendo así correlacionar los varios aspectos y temáticas que abarca cada obra.
- **Investigación científica.** Al igual que en cualquier otro ámbito de la ciencia, la educación también es susceptible de ser encarada desde un paradigma de investigación que presente hipótesis de trabajo, desarrollo de tesis y demostraciones. Este proceso se podría llevar a cabo a partir de lo voluminosa cantidad de datos recopilados en los diferentes y variados procesos presentados anteriormente. Esta aplicación no se centraría únicamente a investigadores como usuarios finales, si no que también este tipo de enfoque podría ser utilizado por diferentes analistas de datos.

## CONCLUSIONES

La computación, y su hija dilecta la inteligencia artificial, han sabido posicionarse como factores esenciales en los más variados procesos, tornándose parte fundamental en la conformación y operación de los diversos artefactos y dispositivos con las que interactuamos en nuestra cotidianeidad. La educación no ha escapado a la irrefrenable participación protagónica de estas tecnologías poseedoras de la más que destacable característica de simular un comportamiento inteligente, siendo que este proceder, como bien sabemos, ésta indefectiblemente asociado al accionar humano.

El primer gran hito de la educación asistida por computador fue el desarrollo de los entornos de aprendizaje interactivo. Al habilitar la interacción con el estudiante y poder tomar diferentes caminos pedagógicos a partir de esta retroalimentación, este tipo de entornos dotó a los primigenios Sistemas de Gestión del Aprendizaje (LMS) de funcionalidades y prestaciones propias de la tutoría personalizada que caracteriza a las clases impartidas en aulas físicas. Naturalmente, estos sistemas montados sobre reglas preestablecidas fueron evolucionando hacia modelos de enseñanza en los que las estrategias de interacción se basan en modelos de aprendizaje estadístico-computacional. A partir de este tipo de forma de diseñar los modelos educativos -que es la que caracteriza al tipo de inteligencia artificial más utilizado en la actualidad: el aprendizaje automático *machine learning*- se generan los Sistemas de Tutoría Inteligente (ITS), que quedan determinados por la presencia de un componente fundamental: el motor adaptativo

inteligente. A su vez se desarrollan modelos adaptativos del tipo ITS que incorporan el más novedoso desarrollo de la Inteligencia artificial, las redes neuronales profundas, modelos que junto a los de aprendizaje automático clásico se engloban en la disciplina denominada Minería de Datos Educativa (EDM).

Las prestaciones y las aplicaciones fundamentales de los sistemas educativos modernos montados sobre los modelos de inteligencia artificial recién descritos se pueden aglutinar en estas áreas fundamentales: corrección, evaluación y calificación, predicción de rendimiento académico, evaluación y generación de recomendaciones personalizadas, detección de comportamiento no deseado y retención de estudiantes. Otras áreas de aplicación de las variadas disciplinas que componen la IA, aun no exploradas, son el trazado de redes sociales que analicen las relaciones entre los educandos, el desarrollo de mapas curriculares y la creación de contenido pedagógico mediante la utilización de redes neuronales generativas.

Claramente la incorporación de estas tecnologías digitales disruptivas y de vanguardia aportan un valor agregado tangible, mensurable y de variado alcance, tal como fue descrito en el desarrollo de este artículo. No obstante ello es menester considerar que su aplicabilidad y campos de acción exigen una política mancomunada y consistente de inserción y de democratización de las tecnologías digitales en diferentes ámbitos y estratos sociales. Es por ello que lo que se busca aquí es presentar un panorama de la aplicación de la Inteligencia Artificial, paradigma del avance tecnológico actual, en la educación, relevando para ello su historia, potencial, aplicación y el estado del arte de la investigación científica en la materia, con el fin de incentivar su adaptación, desarrollo e implementación en diferentes sociedades y sistemas educativos tanto a nivel nacional, regional y global.

## **BIBLIOGRAFIA**

- [1] K. Flamm (1988) . "Creating the Computer: Government, Industry, and High Technology." Washington, DC, USA: Brookings Institution Press.
- [2] M. M. L. Cairns (2017)- "Computers in education: The impact on schools and classrooms," in Life Schools Classrooms. Singapore: Springer, ,pp. 603\_617.
- [3] B. Coppin (2004). "Artificial Intelligence Illuminated". Boston, MA, USA: Jones and Bartlett.
- [4] B. Whitby (2008). "Artificial Intelligence: A Beginner's Guide." Oxford, U.K.: Oneworld.
- [5] M. Chassignol, A. Khoroshavin, A. Klimova, and A. Bilyatdinova (2018). "Artificial intelligence trends in education: A narrative overview," Procedia Comput. Sci., vol. 136, pp. 16\_24.

- [6] V. Devedic (2004). "Web intelligence and artificial intelligence in education" *Educ. Technol. Soc.*, vol. 7, no. 4, pp. 29\_39
- [7] H. T. Kahraman, S. Sagioglu, and I. Colak (2010). "Development of adaptive and intelligent Web-based educational systems," in *Proc. 4th Int. Conf. Appl. Inf. Commun. Technol.*, Oct. 2010, pp. 1-5.
- [8] R. Peredo, A. Canales, A. Menchaca, and I. Peredo (2011). "Intelligent Webbased education system for adaptive learning," *Expert Syst. Appl.*, vol. 38, no. 12, pp. 14690\_14702, Nov. 2011.
- [9] Wang D. et al. (2015). "A problem solving oriented intelligent tutoring system to improve students' acquisition of basic computer skills". *Comput. Educ.* 2015.
- [10] Ma W. et al. (2014). "Intelligent Tutoring Systems and Learning Outcomes: A Meta-Analysis". *J. Educ. Psychol.* 2014.
- [11] VanLehn K. et al. (2002). "The Architecture of Why2-Atlas: A Coach for Qualitative Physics Essay Writing". 6th Int. Conf. ITS 2002 Biarritz, Fr. San Sebastian, Spain, June 2-7, 2002 *Proc.* 2002.
- [12] Sabo K.E. et al. (2013). "Searching for the two sigma advantage: Evaluating algebra intelligent tutors". *Comput. Human Behav.* 2013.
- [13] Zhang B., Jia J. (2017). "Evaluating an intelligent tutoring system for personalized math teaching". *Proceedings - 2017 International Symposium on Educational Technology, ISET 2017.*
- [14] Mahmoud M.H., Abo El-Hamayed S.H. (2016). "An intelligent tutoring system for teaching the grammar of the Arabic language". *J. Electr. Syst. Inf. Technol.* 2016.
- [15] Sung Y.T. et al. (2016). "The effect of online summary assessment and feedback system on the summary writing on 6th graders: The LSA-based technique". *Comput. Educ.* 2016.
- [16] Koedinger K.R. et al. (2013). "New potentials for data-driven intelligent tutoring system development and optimization". *AI Mag.* 2013.
- [17] Frize M., Frasson C. (2000). "Decision-support and intelligent tutoring systems in medical education" *Clin. Invest. Med.*

- [18] Al Emran M., Shaalan K. (2014). "A Survey of Intelligent Language Tutoring Systems". Proceedings of the 2014 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2014.
- [19] Dzikovska M.O. et al. (2010). "BEETLE II: a system for tutoring and computational linguistics experimentation". Computational Linguistics..
- [20] Brusilovsky, P. and Peylo, C. (2003) "Adaptive and intelligent Web-based educational systems". International Journal of Artificial Intelligence in Education 13 (2-4), 159-172
- [21] Deloitte Res., Deloitte China, Deloitte Company, (2019). "Global Development of AI-Based Education"
- [22] Hastie, Trevor, Robert Tibshirani and J. H. Friedman. (2009). "The Elements of Statistical Learning: Data Mining, Inference, and Prediction". New York: Springer.
- [23] Bishop, Christopher M. (2006). "Pattern Recognition and Machine Learning." New York :Springer.
- [24] Samuel, A. L. (1959). "Some studies in machine learning using the game of checkers". IBM Journal of research and development, 3(3), 210-229.
- [25] Mitchell, Tom M.(1997) "Machine Learning. New York: McGraw-Hill.
- [26] C. Romero, S. Ventura, M. Pechenizkiy, and R. Baker (2010). "Handbook of educational data mining". CRC Press.
- [27] Abbott, R. G. (2006). "Automated expert modeling for automated student evaluation." In International Conference on Intelligent Tutoring Systems (pp. 1-10). Springer, Berlin, Heidelberg.
- [28] K. Taghipour and H. T. Ng (2016). "A Neural Approach to Automated Essay Scoring," in Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, pp. 1882–1891, Association for Computational Linguistics, Austin, Texas.
- [29] Y. Zhang, R. Shah, and M. Chi (2018). "Deep learning + student modeling + clustering: a recipe for effective automatic short answer grading" in Proceedings of the 9th International Conference on Educational Data Mining (EDM)
- [30] B. Akram, W. Min, E. N. Wiebe, B. W. Mott, K. Boyer, and J. C. Lester (2018). "Improving stealth assessment in game-based learning with lstm-based analytics," in Proceedings of the 11th International Conference on Educational Data Mining. (EDM)

- [31] H. Choi, Z.Wang, C. Brooks, K. Collins-Thompson, B. G. Reed, and D. Fitch (2017) “Social work in the classroom? A tool to evaluate topical relevance in student writing,” in Proceedings of the 10th International Conference on Educational Data Mining. (EDM)
- [32] Sales, A. Botelho, T. Patikorn, and N. T. Heffernan (2018). “Using big data to sharpen design-based inference in A/B tests,” in Proceedings of the 11th International Conference on Educational Data Mining. (EDM)
- [33] Đambić, G., Krajcar, M. & Bele, D. (2016).” Machine learning model for early detection of higher education students that need additional attention in introductory programming courses”. International Journal of Digital Technology & Economy, 1 (1), 1-11
- [34] Delen, D. (2010). “A comparative analysis of machine learning techniques for student retention management”. Decision Support Systems, 49(4), 498-506.
- [35] Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). “Dropout prediction in elearning courses through the combination of machine learning techniques”. Computers & Education, 53(3), 950-965.
- [36] Ram, Wang, Y., Currim, F., & Currim, S. (2015). “Using big data for predicting freshmen retention”. ICIS 2015.
- [37] Chai, K. E., & Gibson, D. (2015). “Predicting the Risk of Attrition for Undergraduate Students with Time Based Modelling”. International Association for Development of the Information Society.
- [38] Jia, J. W., & Mareboyana, M. (2014). “Predictive models for undergraduate student retention using machine learning algorithms”. In Transactions on Engineering Technologies (pp. 315-329). Springer, Dordrecht.
- [39] W. Min, J. B. Wiggins, L. Pezzullo et al. (2016). “Predicting dialogue acts for intelligent virtual agents with multimodal student interaction data,” in Proceedings of the 9th International Conference on Educational Data Mining, pp. 454–459.
- [40] Sharma, A. Biswas, A. Gandhi, S. Patil, and O. Deshmukh (2016). “LIVELINET: A multimodal deep recurrent neural network to predict liveliness in educational videos,” in Proceedings of the 9th International Conference on Educational Data Mining, pp. 215– 222.
- [41] J. Yang, K.Wang, X. Peng, and Y. Qiao (2018). “Deep recurrent multiinstance learning with spatio-temporal features for engagement intensity prediction,” in Proceedings of the 20th ACM International Conference on Multimodal Interaction, (ICMI '18), pp. 594–598, Boulder, CO, USA.

- [42] M. Aung, A. Ramakrishnan, and J.Whitehill (2018). “Who are they looking at? automatic eye gaze following for classroom observation video analysis,” in Proceedings of the 11th International Conference on Educational Data Mining, pp. 166–170, Xi’an,China.
- [43]Anand, V. K., Rahiman, S. A., George, E. B., & Huda, A. S. (2018).” Recursive clustering technique for students’ performance evaluation in programming courses”. In Majan International Conference (MIC), 2018 (pp. 1-5). IEEE.
- [44]Alam, M. M., Mohiuddin, K., Das, A. K., Islam, M. K., Kaonain, M. S., & Ali, M. H. (2018). “A Reduced feature based neural network approach to classify the category of students”. In Proceedings of the 2nd International Conference on Innovation in Artificial Intelligence (pp. 28-32). ACM.
- [45]B. Guo, R. Zhang, G. Xu, C. Shi, and L. Yang (2015). “Predicting students performance in educational data mining,” in Proceedings of the International Symposium on Educational Technology, (ISET ’15), pp. 125–128, China.
- [46]F. Okubo, T. Yamashita, A. Shimada, and H. Ogata (2017). “A neural network approach for students’ performance prediction,” in Proceedings of the the Seventh International LearningAnalytics & Knowledge Conference (LAK ’17), pp. 598-599, ACM.,NewYork, NY, USA.
- [47]B. Kim, E. Vizitei, and V. Ganapathi (2018). “Gritnet 2: Real-time student performance prediction with domain adaptation,” 2018, <https://arxiv.org/abs/1809.06686>.
- [48]B. Kim, E. Vizitei, and V. Ganapathi (2018). “Gritnet: Student performance prediction with deep learning,” 2018, <https://arxiv.org/abs/1804.07405>.
- [49]Ciolacu, M., Tehrani, A. F., Beer, R., & Popp, H. (2017). “Education 4.0—Fostering student’s performance with machine learning methods”. In Design and Technology in Electronic Packaging (SIITME), 2017 IEEE 23rd International Symposium for (pp. 438-443). IEEE.
- [50] K. Abhinav, V. Subramanian, A. Dubey, P. Bhat, and A. D. Venkat (2018). “Lecore: A framework for modeling learner’s preference,” in Proceedings of the 11th International Conference on Educational Data Mining.
- [51] C. Wong (2018). “Sequence based course recommender for personalized curriculum planning,” in Artificial Intelligence in Education, vol. 10948 of Lecture Notes in Computer Science, pp. 531–534, Springer International Publishing.
- [52]Antonio Hernández-Blanco, Boris Herrera-Flores, David Tomás, Borja Navarro-Colorado (2019). "A Systematic Review of Deep Learning Approaches to Educational

Data Mining", Complexity, vol. 2019, Article ID 1306039, 22 pages,  
<https://doi.org/10.1155/2019/1306039>

- [53] Rallo, R., Gisbert, M., & Salinas, J. (1999). "Using data mining and social networks to analyze the structure and content of educative on-line communities". Analysis, 468(472), 473.
- [54] Agrawal, R., Gollapudi, S., Kannan, A., & Kenthapadi, K. (2014). "Study navigator: An algorithmically generated aid for learning from electronic textbooks". JEDM-Journal of Educational Data Mining, 6(1), 53–75.