

KOMPUTER SAPIENS

Año 16
Volumen 2
Mayo - Ago 2024

Revista de Divulgación de la Sociedad Mexicana de Inteligencia Artificial

INTELIGENCIA ARTIFICIAL EXPLICABLE

IA PARA CREAR PROTOCOLOS DE INVESTIGACIÓN

ChatGPT: ¿UNA BENDICIÓN O UNA MALDICIÓN PARA LA EDUCACIÓN EN MÉXICO?

EVALUANDO LA ATENCIÓN DE ESTUDIANTES CON IA

ChatGPT COMO HERRAMIENTA EN LA EDUCACIÓN

ABUSO Y APROVECHAMIENTO DE LA IA EN LA EDUCACIÓN

APRENDIZAJE PARTICIPATIVO CON ChatGPT

LA COMPUTACIÓN AFECTIVA EN LA EDUCACIÓN

MINERÍA DE DATOS PARA ANALIZAR RESULTADOS DE MATEMÁTICAS

IA GENERATIVA PARA FOMENTAR LA LECTURA

```

# Creamos datos ficticios para ilustrar el
matematicas = np.array([80, 85, 70, 90, 95,
fisica = np.array([75, 70, 85, 80, 90,
química = np.array([70, 75, 80, 85, 95, 65]) # Calificaciones
calificacion_final = np.array([85, 80, 90, 88, 92, 70]) # Calificación final

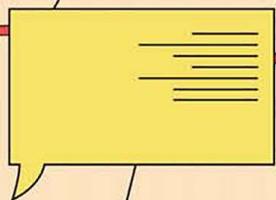
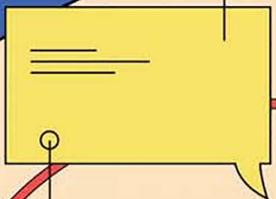
# Dividir los datos en conjuntos de entrenamiento y prueba
train, X_test, y_train, y_test = train_test_split(X, calificacion_final,
random_state=42)

# Crear un modelo de regresión lineal
modelo = LinearRegression()
modelo.fit(X_train, y_train)

# Realizar predicciones en el conjunto de prueba
predicciones = modelo.predict(X_test)

# Evaluar el rendimiento del modelo
error_cuadratico_medio = mean_squared_error(y_test, predicciones)
print("Error cuadrático medio: ", error_cuadratico_medio)

```



Message ChatGPT...



©Komputer Sapiens, Año XVI Volumen II, mayo-agosto 2024, es una publicación cuatrimestral de la Sociedad Mexicana de Inteligencia Artificial, A.C., con domicilio en Ezequiel Montes 56 s/n, Fracc. los Pilares, Metepec, Edo. de México, C.P. 52159, México, <http://www.komputersapiens.org>, correo electrónico: editorial@komputersapiens.org, tel. +52 (833)357.48.20 ext. 3024, fax +52 (833) 215.85.44. Impresa por Sistemas y Diseños de México S.A. de C.V., calle Aragón No. 190, colonia

Álamos, delegación Benito Juárez, México D.F., C.P. 03400, México, se terminó de editar el 30 de abril de 2024. Reserva de derechos al uso exclusivo número 04-2009-111110040200-102 otorgado por el Instituto Nacional de Derechos de Autor. ISSN 2007-0691.

Los artículos y columnas firmados son responsabilidad exclusiva de los autores y no reflejan necesariamente los puntos de vista de la Sociedad Mexicana de Inteligencia Artificial. La mención de empresas o productos específicos en las páginas de Komputer Sapiens no implica su respaldo por la Sociedad Mexicana de Inteligencia Artificial. Queda estrictamente prohibida la reproducción total o parcial por cualquier medio, de la información aquí contenida sin autorización por escrito de los editores.

Komputer Sapiens es una revista de divulgación en idioma español de temas relacionados con la inteligencia artificial. Creada en \LaTeX , con la clase **papertex** disponible en el repositorio *CTAN*: Comprehensive TeX Archive Network, <http://www.ctan.org/>

Indizada en el IRMDCT de CONACYT y en Latindex.

Presidenta	Directorio SMIA María Lourdes Martínez Villaseñor	Directores Fundadores Carlos Alberto Reyes García	María Lucia Barrón Estrada
Vicepresidenta	Hiram Eredín Ponce Espinosa	Ángel Kuri Morales	Maritza Bustos
Secretario	Roberto Antonio Vázquez Espinosa de los Monteros	Comité Editorial Ildar Batyrshin	Nancy Pérez-Castro
Tesorero	Gilberto Ochoa Ruiz	Oscar Herrera Alcántara	Néstor Leyva López
Vocales:	Gustavo Arroyo Figueroa	Jesús Favela Vara	Rafael Morales Gamboa
	Noé Alejandro Castro Sánchez	Sofía Natalia Galicia Haro	Ramón Zatarain Cabada
	Hugo Jair Escalante Balderas	Miguel González Mendoza	Raúl Oramas Bustillos
	Sofía Natalia Galicia Haro	Raúl Monroy Borja	Rocío Barrientos Martínez
	Antonio Marín Hernández	Eduardo F. Morales Manzanares	Samuel González López
	Bella Citlali Martínez Seis	Leonardo Garrido Luna	Víctor Manuel Bátiz Beltrán
	Iris Iddaly Méndez Gurrola	Carlos Alberto Reyes García	
	Leobardo Morales Tiburcio	Antonio Sánchez Aguilar	
	César Jesús Núñez Prado	Luis Enrique Sucar Succar	
	Iván Alejandro Olvera Rodríguez	Ángel Kuri Morales	
	Obdulia Pichardo Lagunas	José A. Martínez Flores	
	David Eduardo Pinto Avendaño	Juan Manuel Ahuactzin Larios	
	Victor Josué Ruiz Martínez	Manuel Montes y Gómez	
	Komputer Sapiens María Lourdes Martínez Villaseñor	Ofelia Cervantes Villagómez	
Directora general	Karina Mariela Figueroa Mora	Alexander Gelbukh	
Editora en jefe	Héctor Gabriel Acosta Mesa	Grigori Sidorov	
Editor científico	Marco Antonio Aguirre Lam	Laura Cruz Reyes	
Editores asociados	Laura Cruz Reyes	Ramon Brena Pinero	
	Ramón Zatarain Cabada	Juan Humberto Sossa Azuela	
Editores invitados	María Lucia Barrón Estrada	Félix Castro	
	Viridiana Mena Gómez	Árbitros Adriana Laura López-Lobato	
Coordinadora de producción e-Tlakuilo	Karina Figueroa	Aldo Márquez-Grajales	
	Rosa María Valdovinos	Aldo Uriarte Portillo	
Estado del IArte	Reyna Carolina Medina Ramírez	Ángel Leonel Ortiz Herrera	
	Jorge Rafael Gutiérrez Pulido	Carlos A. Reyes García	
Sakbe	Claudia G. Gómez Santillán	Carlos Alberto Lara Álvarez	
	Laura Cruz Reyes	Efrén Mezura Montes	
IA & Educación	Laura Gómez Cruz	Giner Alor Hernández	
	María Yasmín Hernández Pérez	Gloria E. Peralta Peñuñuri	
	María Lucía Barrón Estrada	Guillermo Hoyos-Rivera	
Deskubriendo Konocimiento	J. Julieta Noguez Monroy	Héctor Acosta Meza	
	Alejandro Guerra Hernández	Héctor Cárdenas-López	
	Gildardo Sánchez Ante	Héctor Rodríguez Rangel	
Corrección de estilo	Gilberto Rivera Zárate	Hugo a. Mitre Hernández	
	Guillermo de Jesús Hoyos Rivera	Isidro Vargas Moreno	
	Héctor Joaquín Fraire Huacuja	Jesús Miguel García-Gorrostieta	
	Leonardo Romero Muñoz	José Luis Llaguno Roque	
	Luis Miguel García Velázquez	José Luis Reyes	
	Marcela Quiroz Castellanos	Karina M. Figueroa Mora	
	Nelson Rangel Valdez	Lourdes Martínez Villaseñor	
	Sonia Lilia Mestizo Gutiérrez	Luis Alberto Morales Rosales	
	Susana Aurora Velasco Montiel		
	María Fernanda Hernández Arroyo		



Contenido

La computación afectiva en la educación

Pág. 7 ⇒ Ramón Zatarain Cabada y Maria Lucia Barrón Estrada

Abuso y aprovechamiento de la inteligencia artificial en la enseñanza y el aprendizaje

Pág. 12 ⇒ Mauricio Priego Montero, Diego Oliva, Itzel Aranguren, Arturo Valdivia Gonzalez, Oscar Ramos-Soto, Angel Casas y Marco Perez-Cisneros

Aprendizaje participativo con ChatGPT: una nueva era de interacción, evaluación y retroalimentación

Pág. 18 ⇒ Cesar Camacho-Bello, Alma López-Hernández, Lucia Gutiérrez-Lazcano y José Hernández-Reyes

Chat GPT: ¿Una bendición o una maldición para la educación en México?

Pág. 25 ⇒ Eduardo H. Haro, Nayeli Areli Pérez Padilla y Omar Avalos

Incorporación de ChatGPT como herramienta para la enseñanza de Ciencias Básicas

Pág. 30 ⇒ Elena Elsa Bricio Barrios, Santiago Arceo Díaz y Flabio Darío Mirelez Delgado

Fomentando la lectura y la imaginación en cuentos infantiles con Inteligencia Artificial Generativa

Pág. 36 ⇒ Nayeli Joaquinita Meléndez Acosta, Edmundo Bonilla Huerta, José Federico Ramírez Cruz y Yesenia N. González

Procesamiento de lenguaje natural para crear protocolos de proyectos de investigación de machine learning

Pág. 42 ⇒ César Primero-Huerta y Eddy Sánchez-De la Cruz

Uso del Aprendizaje Automático para Evaluar la Atención en los Estudiantes

Pág. 47 ⇒ Ricardo H. Merlos-Garcia, Yesenia Nohemí González Meneses, Blanca Estela Pedroza Méndez y Elizabeth Cuatecontzi Cuahutle

Explicabilidad y los Métodos de la Inteligencia Artificial Explicable

Pág. 52 ⇒ Humberto de Jesús Ochoa Domínguez

Uso del Algoritmo K-medias para el Análisis de Resultados de Matemáticas en la Prueba Planea 2017

Pág. 57 ⇒ Israel Gutiérrez González, Doricela Gutiérrez Cruz, Octavio Juárez Barrera, Carmen Liliana Rodríguez Páez y Ricardo Rico Molina

Columnas

Sapiens Piensa.
Editorial [pág. 2](#)

e-Tlakuilo [pág. 4](#)

Estado del IArte [pág. 5](#)

Sakbe [pág. 6](#)

IA & Educación [pág. 62](#)

Deskubriendo
Konocimiento [pág. 64](#)

Sapiens Piensa

María Lucia Barrón Estrada y Ramón Zatarain Cabada

La inteligencia artificial (IA) influye actualmente en una amplia gama de actividades que desarrollamos cotidianamente en nuestra vida. El impacto de la IA se percibe en el incremento de procedimientos y actividades del comercio y la industria donde se implementaron nuevas tecnologías para mejorar la eficiencia general. Por otra parte, en el ámbito educativo la IA tiene el poder de cambiar completamente el escenario para los estudiantes al incorporar módulos inteligentes a los sistemas educativos que permitan brindar una instrucción más individualizada, una evaluación adaptativa, un seguimiento del aprendizaje y un manejo emocional, entre otros. Las nuevas tecnologías de software y hardware, que con frecuencia se incorporan al escenario educativo, permiten producir mejores resultados durante el proceso de aprendizaje del estudiante. Un ejemplo de ello es la IA generativa, cuyo producto más icónico e importante en la actualidad es el ChatGPT, que ofrece la posibilidad de producir texto, imágenes u otros medios en respuesta a comandos del usuario, produciendo cambios en los procesos de enseñanza y aprendizaje en las instituciones educativas.

Áreas tradicionales de la IA como el procesamiento de lenguaje natural, el aprendizaje máquina o la computación afectiva, siguen activamente en desarrollo y se utilizan para generar nuevas herramientas de software que permiten mejorar las formas de enseñar a nuestros niños y jóvenes en las escuelas.

En este número de *Komputer Sapiens*, se presentan 10 artículos que abordan temas relacionados a las técnicas de IA aplicadas en la Educación entre las que se encuentran: Explicabilidad, Aprendizaje Automático, Minería de Datos, IA Generativa o de Computación Afectiva. Los artículos fueron seleccionados cuidadosamente por el consejo editorial designado a partir de dos o tres evaluaciones realizadas por las personas del Comité Técnico, conformado por expertos del área. Las personas que realizaron la revisión de cada trabajo examinaron aspectos como el tema a abordar (IA en Educación), la relevancia, la calidad de la exposición del tema, la legibilidad y el enfoque a la divulgación.

En el trabajo **Compu-Educación: un nuevo paradigma educativo**, los autores describen los cambios que surgen en estudiantes que están inmersos en ambientes de aprendizaje basados en la experiencia interactiva, donde los estímulos visuales y auditivos son un medio para mejorar el aprendizaje en el aula; para ello, presentan en su trabajo ejemplos de la evolución desde las enciclopedias digitales, los foros de discusión, los asistentes digitales hasta llegar a los chatbox en donde el ChatGPT es el caso más representativo.

Los autores de **Procesamiento de Lenguaje Natural para crear protocolos de proyectos de investigación de Aprendizaje Máquina** proponen un framework capaz de generar un protocolo de investigación, a partir de la información proporcionada por los usuarios. Esta herramienta fue implementada combinando aprendizaje máquina, ingeniería de software y una plantilla de procesamiento del lenguaje natural. Durante las pruebas los resultados fueron en su mayoría aceptables y sin errores ortográficos ni gramaticales, lo que muestra su utilidad para el propósito con el que fue creado.

Por otra parte, en el artículo **Chat GPT: ¿Una bendición o una maldición para la educación en México?** sus autores responden a la importante pregunta ¿qué pasará cuando ChatGPT incursione de forma masiva en la educación? Para ello, argumentan que “En realidad ya lo están haciendo, aunque en etapas tempranas, pero es cuestión de tiempo para que su uso se extienda por todo México, así que, en lugar de seguir tendencias alarmistas o negativas tratemos de analizar los beneficios y problemas de ChatGPT en la educación mexicana científicamente antes de sacar conclusiones”. Discutiendo después las oportunidades que ChatGPT ofrece a la educación en el mundo y particularmente en México. Por otra parte, también discuten sobre los peligros de un mal uso de ChatGPT en la educación, finalizando con una discusión acerca de la educación en México junto con acciones tempranas o consecuencias duraderas.

En su trabajo **Uso del Aprendizaje Automático para evaluar la atención en los estudiantes**, el autor inicia con una breve discusión de conceptos relacionados al aprendizaje máquina presentando a su vez un ejemplo de un perro al que se le quiere enseñar a reconocer diferentes tipos de objetos. Por otra parte, también presenta una recopilación de investigaciones donde han desarrollado diferentes técnicas para lograr obtener el nivel de atención de los alumnos, concluyendo que el aprendizaje máquina puede combinarse con áreas como las matemáticas, el inglés, la interacción entre humanos y robots o los entornos de realidad virtual.

En la creciente área de IA Generativa se presenta también **Fomentando la lectura y la imaginación en cuentos infantiles con Inteligencia Artificial Generativa** en donde se discute un nuevo modelo para la creación de novedosas versiones de libros infantiles digitales de acceso libre. Para ello, los autores presentan una metodología de 6 etapas para la creación de los cuentos. Para las pruebas se usaron los famosos libros titulados “El principito” y “El patito feo” y se realizó un estudio con un enfoque cuantitativo y cualitativo de las respues-

tas de 31 niños de entre 5 y 9 años de una primaria del estado de Oaxaca, para seleccionar imágenes originales o imágenes generadas estilo ilustración y anime.

Otro trabajo relacionado con la IA Generativa es **Incorporación de ChatGPT como herramienta para la enseñanza de Ciencias Básicas**. En este artículo los autores describen los enormes desafíos que se presentaron en la educación durante la pandemia de COVID. En este trabajo presentan la propuesta desarrollada durante el semestre agosto-diciembre de 2023, con la colaboración de estudiantes de diversas carreras del Instituto Tecnológico de Colima que cursaban las asignaturas de Cálculo Vectorial, Métodos Numéricos y Programación, en las que estuvieron usando la herramienta ChatGPT. Al finalizar los temas se realizó un foro de discusión, donde abordaron la experiencia del estudiantado que participó en el estudio.

En **Análisis de resultados en Matemáticas de la Prueba Planea 2017 mediante algoritmos de Minería de Datos**, los autores presentan una investigación donde aplicaron el algoritmo K-Means para analizar patrones de comportamiento sobre los grupos en los que se divide a un conjunto de datos. Utilizaron los resultados de estudiantes en México derivados de la aplicación de la prueba PLANEA 2017 en el área de Matemáticas. Al final de su trabajo, los autores presentan relevantes discusiones de los hallazgos encontrados en los resultados.

Los autores de **Abuso y aprovechamiento de la Inteligencia Artificial en la enseñanza y el aprendizaje** discuten el abuso y aprovechamiento de la IA en el ámbito educativo, con una orientación a las principa-

les tendencias de implementación de esta tecnología. Por otra parte, también se presentan los riesgos asociados, como la posibilidad de generar contenido sesgado o basado en información falsa, lo que subraya la necesidad de abordar los contenidos con un enfoque crítico y responsable. Por último, se menciona la dualidad de oportunidades y desafíos que la IA presenta en la educación.

Siguiendo con temas de IA Generativa aplicada a la educación, en **Aprendizaje participativo con ChatGPT: una nueva era de interacción, evaluación y retroalimentación** los autores analizan el uso de ChatGPT comparándolo con métodos educativos convencionales, buscando entender cómo los estudiantes se adaptan e interactúan con esta modalidad. En los resultados se demuestra que el uso de ChatGPT apoyado con guías docentes fue más efectivo y que los estudiantes lo prefieren por sobre la clase tradicional. El estudio concluye que ChatGPT mejora el proceso educativo, ya que ofrece un método más interactivo y personalizado.

Por último, los autores de **La Computación Afectiva en la educación** nos presentan inicialmente como la computación afectiva se ha integrado a la educación a través de los tradicionales sistemas tutores inteligentes y los ambientes de aprendizaje inteligentes. Después, el trabajo aborda las diferentes modalidades (rostro, voz, texto, etc.) que se utilizan para reconocer afecto en una persona, para posteriormente ejemplificar la integración del reconocimiento de emociones (rostro), de sentimientos (texto) y de personalidad (texto) en ambientes de aprendizaje afectivo.*

SOBRE LOS AUTORES



María Lucia Barón Estrada es Profesora-Investigadora del TecNM-Instituto Tecnológico de Culiacán desde 1985 y su trabajo de investigación se centra en el desarrollo de tecnologías computacionales inteligentes aplicadas a la educación. Pertenece al Sistema Nacional de Investigadores, Sistema Sinaloense de Investigadores y Tecnólogos, Academia Mexicana de Computación y la Red temática de Inteligencia Computacional Aplicada (REDICA).



Ramón Zatarain Cabada es Doctor en Ciencias de la Computación por el Florida Tech, es Profesor-Investigador en la División de Estudios de Posgrado e Investigación del TecNM-Instituto Tecnológico de Culiacán, una de sus líneas de investigación es computación afectiva aplicada a la educación. Es miembro del Sistema Nacional de Investigadores (SNI), el Sistema Sinaloense de Investigadores y Tecnólogos (SSIT) y la Academia Mexicana de Computación..

Explicabilidad y los Métodos de la Inteligencia Artificial Explicable

Humberto de Jesús Ochoa Domínguez

La Importancia de las Explicaciones

Las explicaciones surgen por el afán de las personas por comprender algo. La mayor motivación de contar con un conjunto de fundamentos útiles para explicar algo, la constituye aquello que no se puede explicar o que desafía a nuestro entendimiento. Sin embargo, la inteligencia humana permite cuestionar para aclarar las razones que existen detrás de la toma de una decisión.

La inteligencia busca explicar situaciones que no son claras o aclarar aquellas que se encuentran oscuras o confusas, utilizando el conocimiento adquirido y añadiendo conocimiento nuevo; para ello, se diseñan métodos y sistemas con el fin de dar sentido a nuestras experiencias, como las experiencias de la ciencia y de la religión, las cuales plantean su propio conjunto de explicaciones [1].

La falta de explicaciones en los sistemas nos genera desconfianza porque no entendemos sus decisiones. Esto impacta en muchas áreas de nuestra vida, especialmente en la ética, en la seguridad, en la privacidad, en la educación y en la responsabilidad social.

En este artículo se describen la inteligencia artificial explicable (XAI, por sus siglas en inglés) y los métodos

utilizados para dotar de explicaciones a los modelos. También, se expone una taxonomía para clasificar a dichos métodos.

La Inteligencia Artificial Explicable (XAI)

En los últimos años, la Inteligencia Artificial (IA) se ha convertido en el núcleo de la industria 4.0 y de la medicina 4.0. En esta última, se ha propuesto un sinnúmero de técnicas para ayudar en el diagnóstico de enfermedades. Algunos ejemplos de técnicas utilizadas en la IA son el aprendizaje automático (ML por sus siglas en inglés), las redes neuronales artificiales (ANN por sus siglas en inglés) y el aprendizaje profundo (DL por sus siglas en inglés).

El interés en el desarrollo de herramientas de IA, especialmente de ML y de DL, ha aumentado debido a que los modelos creados dan mejores resultados que los modelos clásicos utilizados en un pasado, ya que explotan la forma en que la mente humana aprende y generaliza los problemas [2].

La inteligencia busca explicar situaciones que no son claras o aclarar aquellas que se encuentra oscuras o confusas utilizando el conocimiento adquirido y añadiendo conocimiento nuevo.

La inteligencia artificial explicable busca modelos que puedan ser comprendidos por los seres humanos, especialmente, en sectores en los que se requiere resolver problemas como en los sectores militares, bancarios y médicos, con el fin de confiar en los modelos. Por lo tanto, los métodos que evalúan la explicabilidad deben proporcionar una explicación clara del modelo, de tal forma que el resultado pueda tener sentido o ser comprensible para los humanos, de aquí que el concepto de transparencia haya ganado importancia en la XAI [2], [3].

Enfoques de la explicabilidad

En el sentido de la transparencia, existen básicamente dos tipos de enfoques para lograr la explicabilidad, el enfoque de cajas blancas y el de cajas negras. El primero cuenta con modelos de baja complejidad que son fáciles de explicarse y de entenderse. Sin embargo, estos

modelos tienen la desventaja de producir resultados menos confiables que los modelos del segundo enfoque y no siempre son capaces de modelar la complejidad inherente de los datos que se les presentan.

Dentro de la clasificación de cajas blancas se encuentran la regresión lineal, la regresión logística, los árboles de decisión y los modelos aditivos generalizados (GAM por sus siglas en inglés). Estas estrategias no sólo proporcionan la decisión final a la que llegan, sino que también explican la importancia de cada característica que entra al modelo.

Las cajas negras producen resultados más precisos, sin embargo, carecen de transparencia debido a que los modelos toman decisiones sin mostrar cómo lo hicieron, ya que se desconoce cómo se estima la importancia de cada característica de entrada al modelo. En esta clasificación, se encuentran los bosques aleatorios, las

máquinas de vector soporte y los modelos de redes neuronales multicapa [3], [4].

Taxonomía de los métodos XAI

La evaluación de la explicabilidad se puede dividir en tres grupos principales: la intervención humana directa, la intervención humana indirecta y la dirigida a la robustez del modelo. En el primer grupo se motiva a que los criterios de evaluación se basen en interacciones directas con humanos. En el segundo grupo se diseñan tareas que requieren que los humanos estén en el ciclo de evaluación sin que ellos midan directamente la explicabilidad. En el grupo dirigido a la robustez del modelo se utilizan métodos para cuestionar la importancia de la explicabilidad y proporcionar una justificación humana, anteponiendo el argumento de que las explicaciones valoran internamente el proceso de toma de decisiones de un modelo y no necesitan ajustarse a la visión humana.

La Figura 1 muestra una taxonomía que clasifica a los métodos para evaluar la explicabilidad en modelos de aprendizaje automático.

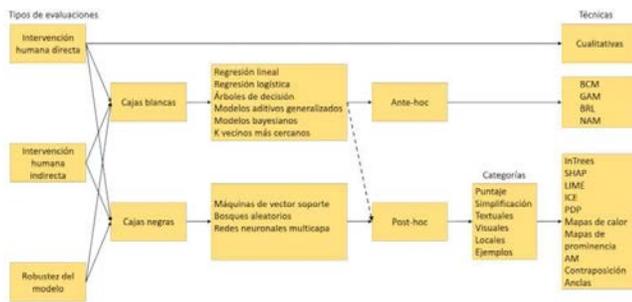


Figura 1. Taxonomía de los métodos XAI.

Métodos ante-hoc

Los métodos ante-hoc incorporan la explicabilidad directamente en el modelo y son fáciles de explicar; las técnicas utilizadas son: el modelo de caso bayesiano (BCM por sus siglas en inglés) que aprende características sobresalientes de los datos para crear modelos que den resultados precisos e interpretables en conjuntos de datos estándar; el modelo aditivo generalizado (GAM por sus siglas en inglés) que captura el impacto de las variables predictivas usando funciones suaves, de esta forma modelan los datos no lineales mientras se mantiene la explicabilidad; la lista de reglas de Bayes (BRL por sus siglas en inglés) que produce una distribución posterior de permutaciones a partir de un conjunto grande de reglas preestablecidas “IF-THEN” que explican automáticamente muchas razones obvias detrás de cada predicción; el modelo neuronal aditivo (NAM por sus siglas en inglés), que es una versión mejorada y escalable del modelo GAM, que puede entrenar múltiples redes neuronales profundas (DNN, por sus siglas en inglés) y aprender una combinación lineal de

redes simplificadas, de una sola entrada, que atienden a una sola característica del vector de entrada [6].

La desventaja de estos métodos es que son específicos para un modelo definido, lo que significa que dependen de un determinado diseño y no pueden volver a usarse en ninguna otra arquitectura.

Métodos post-hoc

Los métodos post-hoc o locales se aplican después de entrenar el modelo, centrándose en los datos y en las distintas rutas que estos toman para dar explicaciones individuales a un resultado o conjunto de resultados. Estos métodos se diseñan para interpretar localmente modelos de caja negra en los que se necesita comprender una decisión específica. En este sentido, los modelos pre-entrenados son más valiosos cuando se puede interpretar la ruta por donde pasan los datos, para que con el modelo y su precisión, se comprenda la decisión del mismo [7].

Estas técnicas se dividen en específicas del modelo y agnósticas o independientes del modelo. Las técnicas de explicación post-hoc más comunes se pueden dividir en las seis categorías descritas a continuación [2], [3]:

1. Las explicaciones basadas en puntaje (ponderaciones impuestas a las características de entrada al modelo) se llevan a cabo con el fin de cuantificar la influencia de cada característica en el resultado final; este tipo de explicaciones es muy sensible en los casos en que las características se encuentren altamente correlacionadas. Una técnica muy usada son los valores de Shapley o técnica SHAP, inspirada en la teoría de juegos, donde se calcula la contribución de cada característica (jugador) a la predicción (resultado del juego) para identificar el impacto que tiene cada entrada en el resultado final [2].
2. Las explicaciones por simplificación se basan en modelos simples que son una aproximación de modelos más complejos; usan árboles de decisión para generar reglas, la técnica preferida es la llamada “InTrees” que es un conjunto de árboles como bosques aleatorios, bosques aleatorios regularizados y árboles potenciados por gradientes, con los que se extraen las reglas; otro tipo de explicación utilizada aquí también son los valores de Shapley ya que los modelos más simples producen reglas fáciles de entender. La desventaja clara es que los modelos generados podrían no aproximarse bien a los modelos originales lo que limita la explicabilidad [2].
3. Las explicaciones textuales se representan a través de símbolos utilizando técnicas de lenguaje natural para describir el desempeño de un modelo, verbalizando la información. Sin embargo, la limitación de este tipo de explicaciones es la dependencia en las

bases de datos que incluyan no sólo secuencias de imágenes, sino también la información semántica que las describen [2], [3].

4. Las explicaciones visuales se generan a través de mapas generados, que se utilizan para entender el modelo. Dentro de esta clasificación se encuentran el gráfico de dependencia parcial (PDP por sus siglas en inglés), utilizada para visualizar el efecto de una o dos características sobre cierta instancia de un resultado, los gráficos de expectativa condicional individual (ICE por sus siglas en inglés) que muestran cómo cambia la predicción del modelo cuando cambia alguna característica, los mapas de calor y los mapas de prominencia, donde a los píxeles de mayor relevancia se les asigna un color diferente.

La maximización de la activación (AM por sus siglas en inglés) es otra técnica visual, utilizada para resaltar la importancia de las características por capa de una red neuronal convolucional (CNN por sus siglas en inglés) [8]. La principal desventaja de las explicaciones visuales es que no existen referencias estandarizadas para evaluarlas de forma cuantitativa y completa.

5. Las explicaciones locales explican cómo opera un modelo en un área de interés determinada; utilizan técnicas como SHAP y las explicaciones locales interpretables (LIME por sus siglas en inglés). Estas explicaciones pueden operar sobre datos tabulares, texto e imágenes. Sin embargo, cuando se trabaja en forma tabular no hay una definición precisa de datos vecinos y las explicaciones se pueden manipular para ocultar sesgos, lo cual limita la confianza en las explicaciones.

Las explicaciones locales también utilizan técnicas de contraposición de hechos o contrafácticas, en las que se describen situaciones causales de la forma “Si no hubiera ocurrido el evento A, no hubiera ocurrido el evento B”. La ventaja de las técnicas contrafácticas es que son fácilmente interpretables por los seres humanos; sin embargo, la complejidad computacional es alta.

Otra técnica utilizada son las anclas, las cuales encuentran una regla de decisión que ancla la predicción, de tal forma que los cambios de los valores de las características de una determinada instancia no afectan la predicción. Las anclas son paralelizables, las explicaciones son fáciles de interpretar y el modelo es agnóstico, lo que significa que puede aplicarse a cualquier modelo. Algunas de las desventajas son que las anclas tienen muchos parámetros a configurar y el tiempo de ejecución es variable ya que depende del rendimiento del modelo [9].

6. Las explicaciones basadas en ejemplos corresponden a métodos en los que las explicaciones se comunican a través de muestras o lotes de muestras que pueden ser ejemplos de entrenamiento (ejemplos naturales) de la base de datos o ejemplos generados sintéticamente. Las explicaciones basadas en ejemplos funcionan bien cuando los datos tienen una estructura, por ejemplo, las imágenes o los textos [10].

En algunos casos, la explicabilidad se ha llegado a confundir con la interpretabilidad, sin embargo, las interpretaciones proporcionan significado a un concepto abstracto para que tenga sentido, por ejemplo, las secuencias de símbolos o vectores abstractos conteniendo palabras desconocidas, traducidas a secuencias de palabras que pueden ser leídas por el ser humano. Por otro lado, las explicaciones conforman un aspecto importante para entender un modelo, estas vienen dadas por un conjunto de características traducidas a un dominio interpretable por el ser humano y que contribuyen a generar una decisión.

Limitaciones

En los últimos años, han surgido con éxito nuevos modelos de cajas negras, privilegiando a las DNN. Esto ha provocado que surja un gran interés por evaluar las decisiones que toman estos modelos; sin embargo, al ser estas una colección seriada de neuronas organizadas en múltiples capas, se requiere de mucho esfuerzo y experimentos adicionales para explicar los resultados. Por otra parte, la XAI asume cierto nivel de experiencia de las personas para interpretar y evaluar la imparcialidad de las decisiones.

Las explicaciones vienen dadas por un conjunto de características traducidas a un dominio interpretable por el ser humano.

Otra limitación importante es el cambio de las explicaciones conforme cambian los datos con el tiempo. Por lo tanto, la brecha entre la toma de decisiones humanas

y las decisiones del modelo hace que la XAI sea una herramienta insuficiente y, en algunos casos, arriesgada [5].

Ejemplo de explicabilidad

En ocasiones, se desconoce cómo las explicaciones, que acompañan la producción de IA, pueden dirigirse a los usuarios. Para clarificar esto, el siguiente ejemplo muestra el uso de la técnica SHAP en un modelo de regresión lineal que explica la influencia de ciertos parámetros muestreados en la sangre sobre la variación del antígeno prostático (PSA sus siglas en inglés), enzima utilizada en la detección del cáncer de próstata. En este caso, se usa el logaritmo (*log*) del PSA (*lpsa*).

Primero, entrenamos el modelo para ponderar cada característica de entrada. La Tabla 1 muestra las ponderaciones resultantes.

Tabla 1. Parámetros resultantes después de entrenar un modelo de regresión lineal para predecir el *lpsa*.

Características de entrada	Ponderación (pesos)
<i>Intersección</i>	2.4523
<i>lcavol</i>	0.7110
<i>lweight</i>	0.4005
<i>age</i>	-0.1115
<i>lbph</i>	0.1090
<i>svi</i>	0.3309
<i>lcp</i>	-0.0568
<i>Gleason</i>	-0.0208
<i>pgg45</i>	0.1503

Posteriormente, utilizamos la explicabilidad para analizar las ponderaciones. La Figura 2 muestra la gráfica de los parámetros de la Tabla 1. Claramente se observa que el log del volumen y del peso del tumor (*lcavol* y *lweight* respectivamente) así como la invasión del cáncer en las vesículas seminales (*svi*) son las tres características más relevantes en la predicción del *lpsa*. Existen otras características, pero el entrenamiento arrojó que son menos relevantes como el crecimiento (hiperplasia) de las células benignas (*lbph*), el índice de Gleason (Gleason), el log de la penetración capsular del cáncer (*lcp*), la edad (*age*) y el porcentaje de puntuaciones de Gleason 4 o 5 (*pgg45*).

Podemos establecer una ecuación de regresión de la forma: $lpsa = 2.4523 + 0.7110 \times lcavol + 0.4005 \times lweight + 0.3309 \times svi + \epsilon$, donde ϵ representa la suma ponderada de las características menos importantes. Utilizando la técnica SHAP, variamos una característica a la vez, mientras las demás permanecen constantes. A continuación, obtenemos el efecto de cada característica de entrada sobre la variación del *lpsa*, dando lugar a la explicación deseada. Por ejemplo, un incremento de una unidad en el “volumen del tumor” incrementa el *lpsa* en 0.711. El factor de invasión del cáncer en vesículas seminales (*svi*) es un factor binario, entonces, la presencia del

cáncer en las vesículas seminales incrementa el *lpsa* en 0.3309.

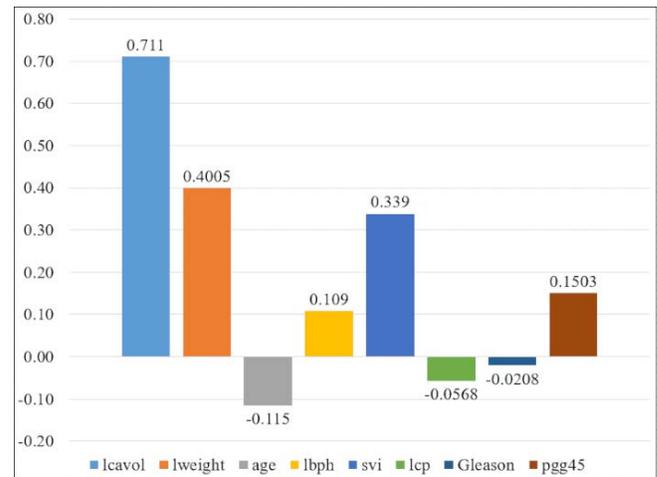


Figura 2. Gráfica de los parámetros involucrados en la predicción del *lpsa*.

Conclusiones

Las técnicas expuestas en este artículo pertenecen a enfoques que se centran en explicar los modelos de ML y su aplicación en entornos del mundo real que, sin comprender a fondo sus limitaciones, pueden crear una falsa sensación de confianza en la toma de decisiones. Es claro que adoptar el trabajo de una IA explicable no es un paso sencillo, sin embargo, los modelos deben perfeccionarse y ampliarse para proporcionar buenos agentes explicativos. Las decisiones deben tomarse en función de muchos factores como el dominio de aplicación (su normativa y características), las necesidades de quien recibe la explicación (es necesario entender el modelo o simplemente acceder al resultado) así como la calidad y las características de los datos a explicar.*

REFERENCIAS

- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267(1), 1–38.
- Borys, K., Schmitt, YA., Nauta, M., et al. (2023). Explainable AI in medical imaging: An overview for clinical practitioners - saliency-based XAI approaches. *Eur. J. Radiol*, 162(1), 1-12.
- Maojo, V. (2023). Informe anticipado: Aplicaciones de la inteligencia artificial en medicina personalizada de precisión. Reporte: M-23713-2023. Instituto Roche. Observatorio de tendencias en la medicina del futuro. Recuperado el 6 de agosto del 2023 de, https://www.institutoroche.es/static/archivos/Informes_anticipando_2023_Aplicaciones_de_la_Inteligencia_Artificial_en_Medicina_Personalizada_de_Precision.pdf.
- Saeed, W., Omlin, Ch. (2023). Explainable AI (XAI): A systematic meta-survey of current challenges and future opportunities. *Knowledge-Based Systems*, 263(1), 1–24.
- Antoniadi, A.M., et al. (2021). Current challenges and future opportunities for XAI in machine learning-based clinical decision support systems: A systematic review. *Applied Science*, 11(11), 1–23.

-
6. Montavon, G., Samek, V., Müller, K-R. (2018). Methods for interpreting and understanding deep neural networks. *Digital Signal Processing*, 73, 1–15.
 7. Zhou, J., Gandomi, AH., Chen, F., et al. (2021). Evaluating the quality of machine learning explanations: a survey on methods and metrics. *Electronics*, 10(5), 593.
 8. Shevskaya, NV. (2021). Explainable artificial intelligence approaches: Challenges and perspectives. En *Proc. 2021 Intl. Conf. on Quality Management, Transport and Information Security, Information Technologies (IT&QM&IS)*, pp. 540–543.
 9. Le, T., Prihatno, AT., Oktian, Y.E., et al. (2023). Exploring local explanation of practical industrial AI applications: A Systematic Literature Review. *Appl. Sci.*, 13(9), 1–28.
 10. Van der Waa, J., Nieuwburg, E., Cremers, A., Neerinx, M., (2021). Evaluating XAI: A comparison of rule-based and example-based explanations. *Artificial Intelligence*, 291, 1–19.
-

SOBRE EL AUTOR



Humberto de Jesús Ochoa Domínguez estudió su licenciatura en el Instituto Tecnológico de Veracruz, su maestría en el Instituto Tecnológico de Chihuahua y su doctorado en la Universidad de Texas en Arlington. Actualmente, es profesor investigador en la Universidad Autónoma de Ciudad Juárez y pertenece al Sistema Nacional de Investigadores nivel 1. Sus áreas de investigación incluyen inteligencia artificial, la inteligencia artificial explicable aplicada a la medicina, la superresolución y la reconstrucción de imágenes para medicina nuclear con aprendizaje profundo.



Imagen tomada de: <https://www.iosb.fraunhofer.de/en/competences/image-exploitation/interactive-analysis-diagnosis/explainable-ai.html>.

Uso del Algoritmo K-medias para el Análisis de Resultados de Matemáticas en la Prueba Planea 2017

Israel Gutiérrez González, Doricela Gutiérrez Cruz, Octavio Juárez Barrera, Carmen Liliana Rodríguez Páez y Ricardo Rico Molina

Introducción

Uno de los principales elementos de análisis del quehacer docente es lo relativo a la forma en la que se enseña y se aprenden las matemáticas en el aula. El personal docente, en los distintos niveles educativos, ha recurrido a diversas estrategias que permitan que el conocimiento sea digerible, atractivo y permanente en los estudiantes. Esto ha conducido a que la investigación en la enseñanza - aprendizaje de las matemáticas sea muy abundante. Diversos factores han sido estudiados como variables que tienen una estrecha relación con el desempeño académico en el área de las matemáticas. Planas [1] asegura que el estudio de factores de índole cultural, social y afectivo permiten mejorar la comprensión del problema del proceso de enseñanza – aprendizaje en el área de las matemáticas. Gil [2] por su parte, enfoca el problema en el papel que juegan los factores afectivos y emocionales en el aprendizaje de las matemáticas.

La infraestructura de las escuelas, el ausentismo de los profesores y la incorporación de los maestros a la carrera magisterial son elementos estudiados por Abreu [3] y que, aseguran, presentan una relación significativa con el logro académico de los estudiantes. Otros aspectos que también se consideran como relevantes en el estudio de los factores inherentes al aprendizaje académico son el proceso acumulativo de conocimiento, la herencia familiar y los insumos escolares como bien establece Petra [4]. Los factores institucionales, las características de los estudiantes, el hogar del estudiante y los antecedentes familiares son elementos que también han sido analizados [5]. Así mismo, diversos autores proponen un análisis

estadístico que puede aportar en la comprensión del fenómeno del aprendizaje en lo que a investigación educativa se refiere [6].

Desde el año 2015, en México se creó el Plan Nacional para la Evaluación de los Aprendizajes PLANEA a cargo de la Secretaría de Educación Pública. El objetivo de esta dependencia es la medición del impacto educativo a través de la aplicación de pruebas para evaluar conocimientos y habilidades de estudiantes de distintos niveles escolares [7].

En México existen algunos trabajos de investigación relacionados con el análisis de datos sobre los resultados de las evaluaciones echas a nivel nacional tales como el trabajo de Campos [8]. En dicha investigación se encuentra una relación entre el nivel obtenido en la evaluación y las calificaciones bimestrales del ciclo escolar en educación primaria. Así mismo puede ser mencionado el sistema ANCONE [9] el cual es un sistema informático que establece las variables que tienen un mayor impacto en las pruebas académicas tales como el nivel de estudios de los padres, los recursos con los que cuenta la familia del estudiante, así como las aspiraciones mismas de estos. De esta forma, el estudio de las variables que tienen una estrecha relación con el aprovechamiento académico, es una constante en lo que a investigación educativa se refiere. En ese trabajo se establece que existen parámetros regionales, culturales y sociales que permiten mejorar la comprensión y el desarrollo de habilidades en las matemáticas. Este estudio puede abonar en el análisis de las estrategias que permitan una mejoría en el proceso de enseñanza – aprendizaje.

Los datos obtenidos de las pruebas estandarizadas puede ayudar a comprender el comportamiento en el rendimiento académico de los alumnos.

Materiales y Métodos

Se tomaron los resultados de la prueba PLANEA aplicada en estudiantes del último grado del nivel medio superior en el área de Matemáticas. Dichos datos fueron obtenidos de la plataforma electrónica del Instituto Nacional para la evaluación de la Educación [10]. A pesar

de que en dicha plataforma se encuentran los resultados de la aplicación de la prueba del año 2015 en adelante, en este trabajo se toma en cuenta el año 2017 con el objetivo de realizar un análisis relativo a los primeros años de aplicación de la prueba. El conjunto de datos está compuesto por distintas variables tanto numéricas como

categorías. Las variables numéricas refieren el porcentaje de estudiantes por escuela que obtuvieron cierto nivel de logro. Los niveles de logro en la prueba PLANEA son un parámetro de suma importancia en la interpretación de nuestros resultados y estos niveles plantean una forma de ubicar a las escuelas y a los estudiantes con base en los conocimientos y habilidades que demuestren. El Nivel I de PLANEA corresponde al nivel de menor rendimiento académico y el Nivel IV corresponde al de mayor aprovechamiento como se muestra en la Tabla 1.

Tabla 1. Clasificación de niveles de aprovechamiento según PLANEA.

Nivel I	Nivel II	Nivel III	Nivel IV
Logro insuficiente	Logro apenas indispensable	Logro Satisfactorio	Logro Sobresaliente

Las variables categóricas que se tomaron en cuenta para la búsqueda de patrones de comportamiento son: nivel de marginación, la entidad federativa y el tipo de sistema educativo. Para la variable “grado de marginación” los valores establecidos en PLANEA son: muy alto, alto, medio, bajo y muy bajo. Respecto de la variable “tipo de sistema educativo”, se evalúan 21 distintos sistemas educativos de nivel medio superior tales como CONALEP, Colegios de Bachilleres, Centros de Estudios Científicos y Tecnológicos, escuelas del IPN, etc. La variable “entidad federativa” tiene como valores los 32 estados de la República Mexicana. En la base de datos descargada, se pueden contabilizar un total de 16380 registros o escuelas que fueron evaluadas en los 32 estados que conforman la República Mexicana. De esta forma los registros pueden verse como vectores que contienen tres variables categóricas y cuatro variables numéricas.

Desarrollo

Para el análisis de datos, se utiliza el algoritmo K-medias (K-means), el cual es un algoritmo de agrupamiento de uso común en la Minería de Datos. Este algoritmo está basado en el cálculo de distancias euclidianas entre los valores numéricos de cada uno de los vectores o registros y un vector de datos representativo de cada grupo. Dicha técnica garantiza, con cierto nivel de confianza, que los elementos de cada grupo obtenido tendrán características que los hacen afines. Por ejemplo, si se tiene un conjunto de 100 registros con cualquier número de variables numéricas y se utiliza el algoritmo con $K=2$, el algoritmo dividirá los 100 datos en dos grupos y los elementos de cada grupo tendrán características en común. En este trabajo el cálculo se realizó haciendo uso del algoritmo K-medias con los valores $K=2$, $K=3$ y $K=4$ pero aquí se reportan únicamente los resultados para $K=3$ grupos ya que para $K=2$ y $K=4$ los resultados y comportamientos fueron análogos. En el caso $K=3$, el algoritmo divide los 16380 registros o escuelas en tres grupos diferentes con características comunes cada uno de ellos. Sobre cada

grupo obtenido, se realizó un análisis de sus características intrínsecas para buscar comportamientos o patrones que permitan catalogar a cada uno de los grupos. Nombramos a los grupos como grupo K1, grupo K2 y grupo K3. En la Tabla 2, se puede visualizar la cantidad de escuelas que corresponden a cada uno de los tres grupos por entidad federativa según lo obtenido al aplicar el algoritmo K-medias. Por ejemplo, el total de escuelas que fueron evaluadas en Aguascalientes fue de 214 de las cuales 30 se agruparon en el grupo K1 (lo que corresponde al 14.02 % del total de las escuelas evaluadas en esta entidad), 85 en el grupo K2 (39.72 %) y 99 en el grupo K3 (46.26 %).

Tabla 2. Cantidad y porcentaje de escuelas en los tres grupos K1, K2 y K3.

Entidad	Número de escuelas por grupo			Porcentaje de escuelas por grupo		
	K1	K2	K3	K1	K2	K3
AGUASCALIENTES	30	85	99	14.02	39.72	46.26
BAJA CALIFORNIA	48	138	177	13.22	38.02	48.76
BAJA CALIFORNIA SUR	18	44	47	16.51	40.37	43.12
CAMPECHE	15	57	62	11.19	42.54	46.27
CHIAPAS	146	164	445	19.34	21.72	58.94
CHIHUAHUA	70	143	267	14.58	29.79	55.63
CIUDAD DE MEXICO	67	133	221	15.91	31.59	52.49
COAHUILA	75	154	258	15.40	31.62	52.98
COLIMA	17	45	54	14.66	38.79	46.55
DURANGO	53	114	119	18.53	39.86	41.61
GUANAJUATO	126	396	412	13.49	42.40	44.11
GUERRERO	80	142	376	13.38	23.75	62.88
HIDALGO	59	249	182	12.04	50.82	37.14
JALISCO	223	399	196	27.26	48.78	23.96
MEXICO	209	707	868	11.71	39.63	48.65
MICHOACAN	71	182	313	12.54	32.16	55.30
MORELOS	34	85	103	15.32	38.29	46.40
NAYARIT	15	55	92	9.26	33.95	56.79
NUEVO LEON	50	95	226	13.48	25.61	60.92
OAXACA	90	261	280	14.26	41.36	44.37
PUEBLA	486	655	441	30.72	41.40	27.88
QUERETARO	64	113	82	24.71	43.63	31.66
QUINTANA ROO	25	63	117	12.20	30.73	57.07
SAN LUIS POTOSI	40	112	305	8.75	24.51	66.74
SINALOA	98	164	164	23.00	38.50	38.50
SONORA	69	131	124	21.30	40.43	38.27
TABASCO	43	79	214	12.80	23.51	63.69
TAMAULIPAS	53	119	226	13.32	29.90	56.78
TLAXCALA	17	91	80	9.04	48.40	42.55
VERACRUZ	230	664	746	14.02	40.49	45.49
YUCATAN	47	127	179	13.31	35.98	50.71
ZACATECAS	54	130	87	19.93	47.97	32.10
TOTAL = 16380						

Para caracterizar a cada grupo, se calculó el promedio de los porcentajes de escuelas que pertenecen a cada nivel de logro por cada uno de los tres grupos quedando estos porcentajes como se visualiza en la Tabla 3.

Tabla 3. Distribución por número y porcentaje de escuelas en los tres grupos K1, K2 y K3 para el Área de Matemáticas.

Grupo	Número de escuelas	Promedio de porcentaje por nivel de logro			
		Nivel I	Nivel II	Nivel III	Nivel IV
K1	2722	20.827	37.541	25.226	15.601
K2	6096	59.927	29.225	8.156	2.696
K3	7562	87.769	9.744	1.971	0.519

La minería de datos permite visualizar que existe correlación entre factores sociales y el rendimiento académico a nivel de secundaria.

Resultados y discusión

El análisis de los datos de la tabla 3 permite ver que existe un escaso porcentaje de escuelas en el nivel IV, de logro sobresaliente (15.6, 2.6 y 0.5 para los grupos K1, K2 y K3 respectivamente), para cada uno de los grupos K. Observando los promedios de porcentaje por nivel de logro, se puede ver que para el grupo K1 se detecta una mayor concentración de escuelas entre los niveles II y III (37.5 y 25.2 respectivamente) los cuales corresponden a los niveles de logro: apenas indispensable y satisfactorio, según la clasificación de niveles de aprovechamiento de PLANEA. De esta forma podemos clasificar al grupo K1 como un grupo que, si bien no es sobresaliente, tiene un desempeño aceptable o satisfactorio por lo que lo clasificamos como grupo de “Logro Satisfactorio”. Así mismo, para el grupo K2 se puede observar una mayor concentración en los niveles I y II (59.9 y 29.2 respectivamente) que corresponden a los niveles de aprovechamiento PLANEA insuficiente y apenas indispensable, por lo que clasificamos al grupo K2 como grupo de “Logro apenas indispensable”. Finalmente, para el grupo K3 se puede ver un porcentaje mayoritario indiscutible en el nivel I (87.7) que corresponde al nivel insuficiente según PLANEA por lo que el grupo K3 concentra un alto porcentaje de escuelas con deficiencias académicas por lo que clasificamos este grupo como un grupo de “Logro insuficiente” (Tabla 4).

Tabla 4. Clasificación de los grupos obtenidos de acuerdo con los niveles PLANEA para el Área de Matemáticas.

Grupo	Clasificación de acuerdo a K-Medias
K1	Logro satisfactorio
K2	Logro apenas indispensable
K3	Logro insuficiente

En la Figura 1 se muestra un gráfico de los porcentajes de escuelas por entidad federativa que se encuentran en los grupos K1 y K3 (rendimientos satisfactorio e insuficiente respectivamente) los cuales consideramos representativos y ordenados del de mayor al de menor porcentaje.

El comportamiento que se puede observar en la Figura 1a es que los estados de Puebla, Jalisco y Querétaro se encuentran entre los estados con un mayor porcentaje de escuelas dentro del grupo K1 de logro satisfactorio. Por otra parte, los estados de San Luis Potosí, Tabasco y Guerrero se encuentran como los primeros estados en tener los mayores porcentajes de escuelas dentro del

grupo K3 de logro insuficiente con más del 50 % de sus escuelas dentro de este grupo (Figura 1b). Para el caso de porcentajes por subsistema, en la Figura 2 se puede observar que los sistemas CETI e IPN dominan en porcentaje en el grupo K1 de nivel satisfactorio en el Área de Matemáticas (Figura 2a), mientras que los sistemas PREECOS y CONALEP DF-OAX se ubican como los sistemas educativos con un menor rendimiento académico al ser mayoritarias en el grupo K3 (Figura 2b). Así mismo, puede observarse que, CETI e IPN se encuentran muy por encima del siguiente subsistema (otras federales) para el caso del grupo K1 y que prácticamente estas instituciones no tienen una sola escuela dentro del grupo K3. Este comportamiento da cuenta del elevado nivel académico que tienen en los sistemas CETI e IPN en el área de matemáticas. Tomando en cuenta la variable nivel de marginación para el análisis, en la figura 3a puede observarse que, si el nivel de marginación es muy bajo, entonces se tiene un mayor porcentaje de escuelas dentro del grupo K1. Por el contrario, para niveles de marginación demasiado altos, hay una preponderancia de escuelas dentro del grupo K3 como puede verse en la figura 3b. Este comportamiento permite establecer que entre mayor es el nivel de marginación, menor será el rendimiento académico y recíprocamente.

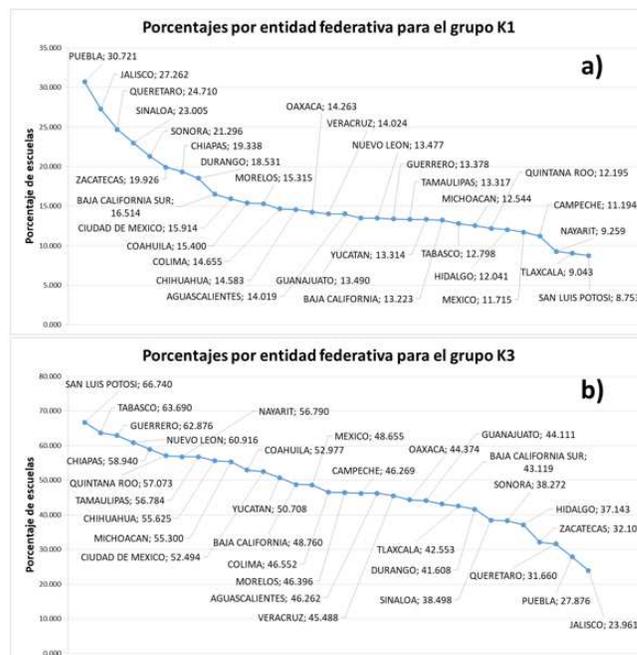


Figura 1. Porcentaje de escuelas evaluadas por PLANEA por entidad federativa para el Área de Matemáticas: a) para

el grupo K1 (de logro satisfactorio), b) para el grupo K3 (de logro insuficiente).

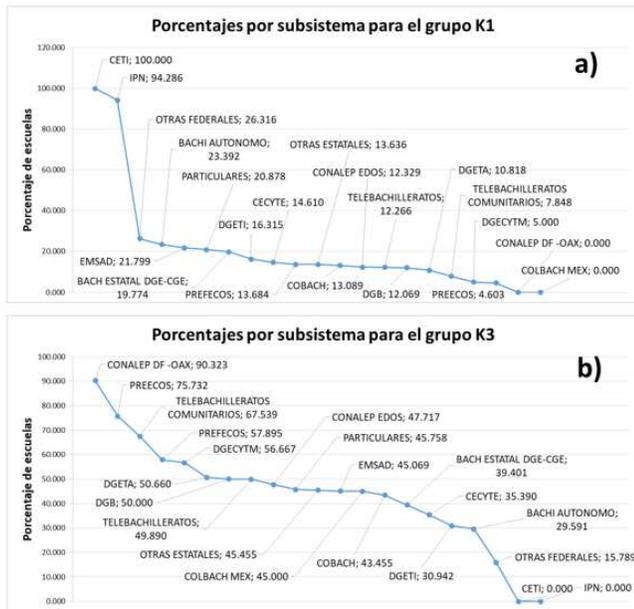


Figura 2. Porcentaje de escuelas evaluadas por PLANEA por subsistema para el Área de Matemáticas: a) para el grupo K1 (de logro satisfactorio), b) para el grupo K3 (de logro insuficiente).

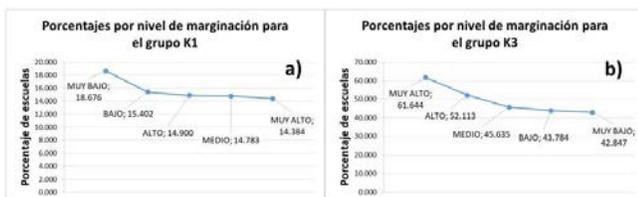


Figura 3. Porcentaje de escuelas evaluadas por PLANEA por nivel de marginación para el Área de Matemáticas: a) para el grupo K1 (de logro satisfactorio), b) para el grupo K3 (de logro insuficiente).

Conclusiones

Se obtienen 3 grupos que clasificamos como de logro satisfactorio (nivel destacado), logro apenas indispensable (nivel intermedio) y logro insuficiente (bajo nivel) respectivamente. En el grupo K1, que corresponde al nivel de logro satisfactorio, se puede destacar una cantidad mayoritaria de escuelas en los estados de Puebla y Jalisco. Estos estados tienen un aprendizaje que los coloca en un nivel de logro satisfactorio respecto de los otros estados. Por el contrario, estados como Tabasco y Guerrero tienen un porcentaje importante de sus escuelas en el grupo K3 de nivel de logro insuficiente. Respecto de la variable subsistema educativo, las instituciones

más destacadas o que pertenecen mayoritariamente al grupo K1, son los bachilleratos CETI y los bachilleratos del IPN. Para el grupo K3 se pueden ubicar a los sistemas CONALEP y PREECOS como aquellos de bajo aprovechamiento en matemáticas e incluso ninguna escuela del IPN o CETI se ubicaron en el grupo K3. Esto indica el buen nivel que tienen estas instituciones en el área de matemáticas. Se encontró que la variable nivel de marginación es un factor que indiscutiblemente afecta el rendimiento académico. Se pudo observar que el grupo K1, de nivel de logro satisfactorio, tiene un mayor porcentaje de escuelas con muy baja marginación mientras que, se puede ver, una cantidad mayoritaria de escuelas en el grupo K3 de nivel de logro insuficiente que se encuentran en marginación muy alta. De esto se concluye que entre mayor sea el nivel de marginación, menor es el rendimiento académico en el área de matemáticas. Por último cabe destacar que, en relación con el estudio del aprovechamiento académico, la minería de datos provee herramientas de análisis que permiten extraer información y encontrar patrones de comportamiento. Los resultados y conclusiones que se obtienen de la aplicación de estos modelos pueden reforzarse y/o complementarse con la analítica del aprendizaje la cual es un área de investigación que se centra en mejorar las metodologías pedagógicas.*

REFERENCIAS

- Planas, N. y Alsina, Á. (2006). Argumentos para los futuros maestros en torno al conocimiento matemático. *Uno: Revista de didáctica de las matemáticas*, 42, 87-98.
- Gil, N., Guerrero, E. y Blanco, L. (2006). El dominio afectivo en el aprendizaje de las Matemáticas. *Electronic Journal of Research in Educational Psychology*, 4(1), 47-72.
- Abreu-Lastra, R. y Calderón-Martín, D. (2007). Índice compuesto de eficacia de los sistemas escolares. Mexicanos Primero Visión 2030 A.C./Fundación IDEA, A.C.
- Petra, T. y Kenneth, W. (2003). On The Specification and Estimation of The Production Function for Cognitive Achievement. *The Economic Journal*, 113(485), 3-33.
- Glewwe, P. y Kremer, M. (2006). Chapter 16 Schools, Teachers, and Education Outcomes in Developing Countries. *Handbook of the Economics of Education*, 2, 945-1017.
- Baker, R. Corbett, A., Koedinger, K. y Wagner, A. (2004). Off-task behavior in the cognitive tutor classroom: When students 'game the system'. *SIGCHI Conf. Human Factors Comput. Syst.*, 383-390.
- INEE. (2015). Plan Nacional para la Evaluación de los Aprendizajes. Disponible en: <https://historico.mejoredu.gob.mx/evaluaciones/planea> (consultado: junio 2022).
- Campos-Vázquez, R. y Urbina, F. (2011). Desempeño educativo en México: la prueba ENLACE. *Estudios Económicos*, 26(2), 249-292.
- Heredia-Márquez, A., Chi-Poot, A., Guzmán-Arenas, A. y Martínez-Luna, G. (2020). ANCONE: An Interactive System for Mining and Visualization of Students Information in the Context of PLANEA 2015. *Revista Computación y Sistemas*, 24(1), 151-176.

SOBRE LOS AUTORES



Israel Gutiérrez González recibió el grado de Dr. en Física de Materiales por la Escuela Superior de Física y Matemáticas del Instituto Politécnico Nacional. Profesor de Tiempo Completo en la Universidad Autónoma del Estado de México en la Ingeniería en Sistemas Inteligentes. Su área de interés en investigación es la programación y aplicación de algoritmos de aprendizaje automático para el análisis de datos.



Doricela Gutiérrez Cruz es profesora de Tiempo Completo de la Universidad Autónoma del Estado de México, adscrita a la ingeniería en sistemas inteligentes, ha escrito diversos artículos relacionados con la Minería de Datos y aprendizaje automático, es Líder del Cuerpo Académico “Diseño de sistema y tecnologías inteligentes” registrado ante la SEP, cuenta con el perfil PRODEP.



Octavio Juárez Barrera es maestro en Ciencias de la Complejidad, realizó sus estudios en la Universidad Autónoma de la Ciudad de México, es maestro en Sociología de la Salud por la Universidad Autónoma del Estado de México, ha realizado investigaciones sobre sistemas de transporte y sistemas complejos. Actualmente está adscrito como profesor Investigador del Centro Universitario UAEM Nezahualcóyotl de la Universidad Autónoma del Estado de México.



Carmen Liliana Rodríguez Páez es Doctora en Ingeniería de Sistemas, en el programa de Posgrado en Ingeniería de la Sección de Estudios de Posgrado en Ingeniería Mecánica y Eléctrica de la ESIME-Zacatenco. Su línea de investigación son los Sistemas de Información, Data Warehouse y Sistemas Basados en Conocimientos.



Ricardo Rico Molina es Doctor en ingeniería de los sistemas impartida en la sección de estudios de posgrados de la ESIME Zacatenco del IPN, obtuvo el grado de maestro en ciencia de los sistemas en la misma institución, fue candidato a investigador SNI del 2013 al 2016. Actualmente esta adscrito como profesor investigador dentro de la Universidad Autónoma del Estado de México.

IA & Educación

Julieta Noguez, Lucía Barrón y Yasmín Hernández

La inteligencia artificial en la educación

Actualmente, la Inteligencia Artificial (IA) se ha vuelto un tema común de conversación y, particularmente, de preocupación en el ámbito educativo debido a las herramientas de IA generativa como ChatGPT [1]. Los estudiantes usan dichas herramientas con frecuencia para tener conversaciones en lenguaje natural y crear contenidos relacionados con sus tareas académicas. En los últimos meses, el uso de herramientas de IA generativa ha provocado un cambio en las reglas del juego en varias industrias, impactando principalmente a la educación. La IA se manifiesta en nuestras interacciones en la vida real mediante sensores y algoritmos en nuestros dispositivos que capturan señales de comportamiento, el internet de las cosas en nuestros hogares, y los sistemas de diálogo con chatbots en los call centers y sistemas de ventas, entre otros, mejorando nuestra experiencia y forma de comunicarnos.

Es importante mencionar que, desde sus inicios, se han realizado esfuerzos significativos para desarrollar e integrar sistemas inteligentes en diversas áreas, incluida la educación, donde se han desarrollado una gran variedad de herramientas que incorporan módulos inteligentes. Estos módulos incorporan técnicas y algoritmos, entre los que destacan el aprendizaje automático (también conocido como machine learning), los agentes inteligentes, técnicas inteligentes de búsqueda, teoría de juegos, representación del conocimiento, redes bayesianas, toma de decisiones complejas, agentes multi-agentes, aprendizaje profundo (*deep learning*), aprendizaje por refuerzo, procesamiento de lenguaje natural, visión computacional y robótica, entre otras [2].

Algunas categorías de aplicaciones computacionales donde la IA provee ventajas al servicio de la educación son las siguientes:

- **Los sistemas tutores inteligentes**, que permiten modelar los procesos cognitivos para optimizar el aprendizaje de los estudiantes [3].
- **Las herramientas de aprendizaje personalizado**, que ofrecen al estudiante materiales, actividades y acciones acordes a sus características o perfiles, necesidades y conocimientos, así como a sus respuestas e interacciones [4].
- **Los ambientes de evaluación adaptativa**, que ajustan las preguntas y problemas que se le pre-

sentan al estudiante para que su aprendizaje sea más eficiente y efectivo, identificando las áreas de oportunidad de aprendizaje del estudiante [5].

- **Las plataformas inteligentes para el trabajo colaborativo**, que buscan contribuir a la forma en que se interactúa en estos espacios, ofreciendo retroalimentación y mejorando la experiencia colaborativa [6].
- **Las plataformas inteligentes de juego**, que incluyen la modelación del jugador acorde a su interacción en tiempo real, la adaptación de la dificultad del juego en forma automática y el procesamiento de lenguaje natural para potenciar un ambiente educativo que permita desarrollar competencias sociales, de comunicación y de trabajo en equipo [7].

Adicionalmente, en la literatura se identifican dos aplicaciones principales de la IA en la administración de las instituciones escolares: a) la automatización de las tareas rutinarias de los docentes, y b) el análisis de grandes volúmenes de información de los sistemas educativos [8].

A pesar de este panorama tan alentador, los docentes enfrentan retos importantes para incorporar los avances de la IA. Por una parte, la población actual en los diferentes niveles de educación básica, media y superior creció usando la tecnología y en su día a día reciben muchísima información, lo que puede poner en desventaja a los profesores de cierta edad abriendo la brecha generacional. Los estudiantes actuales también tienen un sentido de “inmediatez” (requieren respuestas rápidas) y dificultad para profundizar en conceptos complejos, poseen características más visuales, tienen habilidades multi-tarea, tienen poca tolerancia a la frustración, y ofrecen resistencia al trabajo intenso.

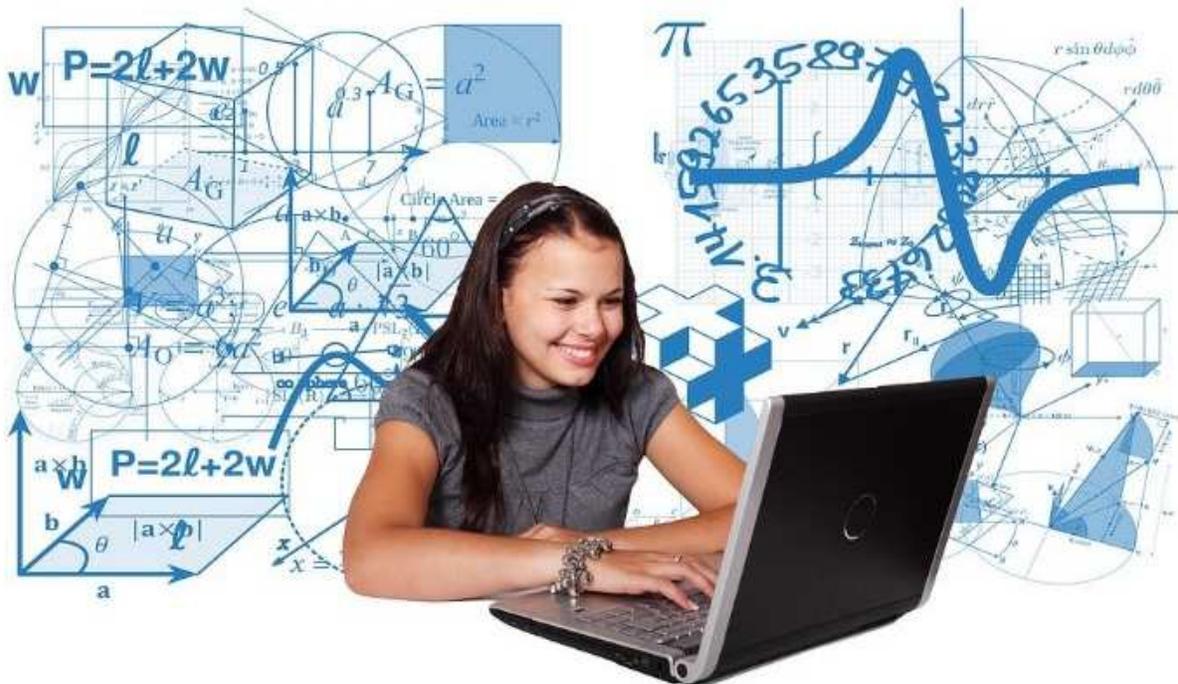
Por otra parte, es necesario que los profesores de los diferentes niveles reciban capacitación y cursos de actualización para aprovechar las herramientas de IA que les permitan innovar las prácticas de enseñanza-aprendizaje y así poder transformar la visión de la educación, permitiendo que los estudiantes incrementen sus capacidades, aprovechen la tecnología y se conviertan en seres que asuman con una mayor responsabilidad cada uno de sus actos.

Sin embargo, los rápidos desarrollos tecnológicos conllevan inevitablemente múltiples riesgos y desafíos, que hasta ahora han superado los debates políticos y los marcos regulatorios. Algunas organizaciones como la UNESCO demandan un enfoque de la IA centrado en el ser humano. Su objetivo es incluir el papel desempeñado por la IA en la solución de las desigualdades actuales en materia de acceso al conocimiento, la investigación y la diversidad de las expresiones culturales, y garantizar que la IA no amplíe la brecha tecnológica al interior de los países y entre ellos. La promesa de la “IA para todos” debe permitir que cada cual pueda sacar provecho de la revolución tecnológica en curso y acceder a sus frutos, fundamentalmente en términos de innovaciones y conocimientos [9].

Hay mucho trabajo por hacer, pero el impacto de la IA en la educación tendrá un efecto profundo en el desempeño de las personas dedicadas a la docencia, y los sistemas escolares se administrarán para participar activamente en mejorar los procesos de enseñanza-aprendizaje en beneficio de los estudiantes.*

REFERENCIAS

1. ChatGPT: Optimizing Language Models for Dialogue, <http://openai.com/blog/chatgpt> (consultada el 24 de enero de 2023)
2. International Journal of Artificial Intelligence in Education (IJAIED). <https://link.springer.com/journal/40593> (consultada el 10 de febrero de 2024)
3. Loures-Elias, A. P. S., & Bernacki, M. L. (2024). The Influence of Affect in Help-Seeking Behaviors and Performance in a Math Intelligent Tutoring System. *IntechOpen*. doi: 10.5772/intechopen.1004185
4. Gonzalez-Nucamendi A., Noguez J., Neri L., Robleda-Rella V. García Castelan R.M. Escobar-Castillejos D.E. (2022). Learning Analytics to Determine Students' Profile Dimensions Associated with their Academic Performance. *Applied Sciences*. ISSN 2076-3417. <https://doi.org/10.3390/app122010560>
5. Clariana R.B., Hooper S. (2012) Adaptive Evaluation Systems. In: Seel N.M. (eds) *Encyclopedia of the Sciences of Learning*. Springer, Boston, MA. DOI: https://doi.org/10.1007/978-1-4419-1428-6_1061.
6. Alanis-Funes G., Neri L., Noguez-J, (2011) Collaborative architecture to support active learning. *Research in Computing Science*, Vol. 53 *Advances in Computer Science and Applications*, Pags. 13-22, CIC-IPN, México, ISSN: 1870-4069
7. Muñoz, K., Noguez, J., Neri, L., Kevitt, P. M., & Lunney, T. (2016). A Computational learning of Learners Achievement Emotions Using Control-Value Theory. *Journal of Educational Technology & Society*, 19 (2), 42–56. ISSN: 1436-4522 (online) and 1176-3647 (print) <http://www.ifets.info/issues.php?show=current>
8. Pedró F., Subosa M., Rivas A., Valverde P. (2019) Artificial Intelligence in Education: Challenges and Opportunities for Sustainable Development. *Working Papers on Education Policy*, 7. UN Educational, Scientific and Cultural Organization (UNESCO). <https://unesdoc.unesco.org/ark:/48223/pf0000366994>
9. La inteligencia artificial en la educación (2024). Aprendizaje digital y transformación de la educación. <https://www.unesco.org/es/digital-education/artificial-intelligence> Consultado el 9 de febrero de 2024



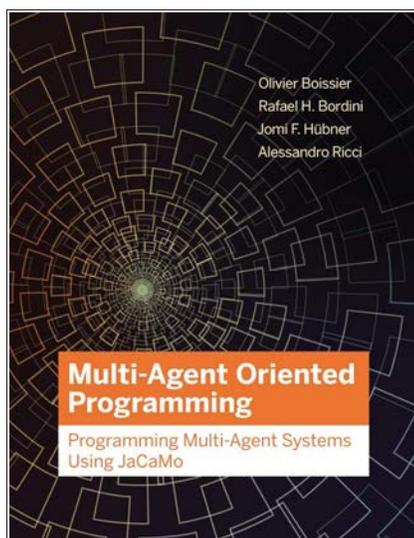
Deskubriendo Konocimiento

Alejandro Guerra Hernández y Gildardo Sánchez Ante
deskubriendokonocimiento@komputersapiens.org

Revisión de “Multi-Agent Oriented Programming” *

Dr. Alejandro Guerra Hernández

Universidad Veracruzana
Instituto de Investigaciones en Inteligencia Artificial



Portada del libro.*

Las computadoras no son muy buenas decidiendo qué hacer. Cada acción ejecutada por una computadora debe ser anticipada, planificada y codificada explícitamente por un programador. Si la computadora enfrenta una situación imprevista el resultado suele ser malo, en el mejor de los casos un fallo del sistema. Aún así, solemos contentarnos con esta visión de la computadora literalmente obediente.

Sin embargo, hay una cantidad creciente de aplicaciones que requieren sistemas que puedan decidir por ellos mismos qué hacer para satisfacer las metas que les delega-

mos. Estos sistemas computacionales se conocen como agentes y, aquellos que operan de manera robusta en ambientes abiertos, dinámicos y difíciles de predecir, suelen ser calificados de inteligentes. Los vehículos espaciales y los controladores aéreos son ejemplos de las aplicaciones en cuestión. Cuando nuestros sistemas computacionales se construyen como un equipo de agentes inteligentes hablamos de Sistemas Multi-Agentes.

El libro que hoy nos ocupa promueve la Programación Orientada a Sistemas Multi-Agente (MAOP, por sus siglas en inglés) como un paradigma para modelar, diseñar y programar estos sistemas. Si bien, podemos encontrar en la literatura del área diversos formalismos, metodologías y lenguajes de programación orientados a agentes, esta propuesta es novedosa al considerar tres dimensiones en estas tareas: agentes, ambientes y organizaciones. Mientras que el capítulo uno introduce brevemente los objetivos del texto, los retos, el enfoque seguido y el público al que va dirigido; el capítulo dos provee una panorámica general de estas dimensiones. El capítulo tres pasa a la práctica e introduce JaCaMo **, una plataforma abierta de desarrollo implemen-

tada en Java para la implementación de sistemas bajo los principios de la MAOP. El sitio web de JaCaMo incluye el código fuente de todos los ejemplos abordados en el libro y otros ejemplos de interés para explorar sus posibilidades.

La dimensión agente es el tema del capítulo cuatro, que introduce el conocido modelo Creencias-Deseos-Intenciones (BDI) con extensiones para la comunicación basada en actos de habla. Las creencias constituyen la información que cada agente tiene acerca de su entorno, en donde intenta satisfacer sus metas o deseos. Las intenciones son pilas de planes que los agentes se comprometen a llevar a cabo para lograr sus metas. Creencias, metas y planes pueden comunicarse usando los actos de habla. Nuestra labor como programadores es proveer a cada agente de creencias, metas y planes iniciales. Los agentes son ejecutados en Jason ***, la implementación en Java de un modelo BDI llamado AgentSpeak(L).

Si bien Jason incluye facilidades para implementar medios ambientes para simulaciones y demos, la verdadera dimensión de ambiente se basa en el meta-modelo de Agentes y Artefactos, el tema del capítulo cinco. Desde esta perspectiva, los

*O. Boissier, R. H. Bordini, J. F. Hübner y A. Ricci. Multi-Agent Oriented Programming: Programming Multi-Agent Systems Using JaCaMo. MIT Press, Cambridge, MA, USA, 2020

**<https://jacamo-lang.github.io>

***R. H. Bordini, J. F. Hübner, y M. Wooldridge. Programming Multi-Agent Systems in Agent-Speak using Jason. John Wiley & Sons Ltd, 2007.

agentes operan en espacios de trabajo locales o remotos, que incluyen una serie de herramientas (los artefactos) para percibir y actuar en el medio ambiente. Las operaciones que los artefactos implementan pueden ser invocadas en los planes de los agentes y sus propiedades son percibidas como creencias. De esta manera los artefactos proveen recursos computacionales a los agentes, sirven como herramientas de coordinación y permiten la interacción con elementos externos al Sistema Multi-Agente. Los espacios de trabajo y los artefactos pueden ser creados por el programador o por los agentes en tiempo de ejecución gracias a la arquitectura CartAgO, que Jacamo incorpora.

Los capítulos seis y siete ponen en práctica estos conceptos para implementar una habitación inteligente pro-activa. Primero el problema se aborda usando un solo agente que controla la temperatura de la habitación con un artefacto aire acondicionado. El énfasis aquí es en la interacción agentes-artefactos, así como la reactividad y robustez del sistema. Posteriormente se explora la idea de usar varios agen-

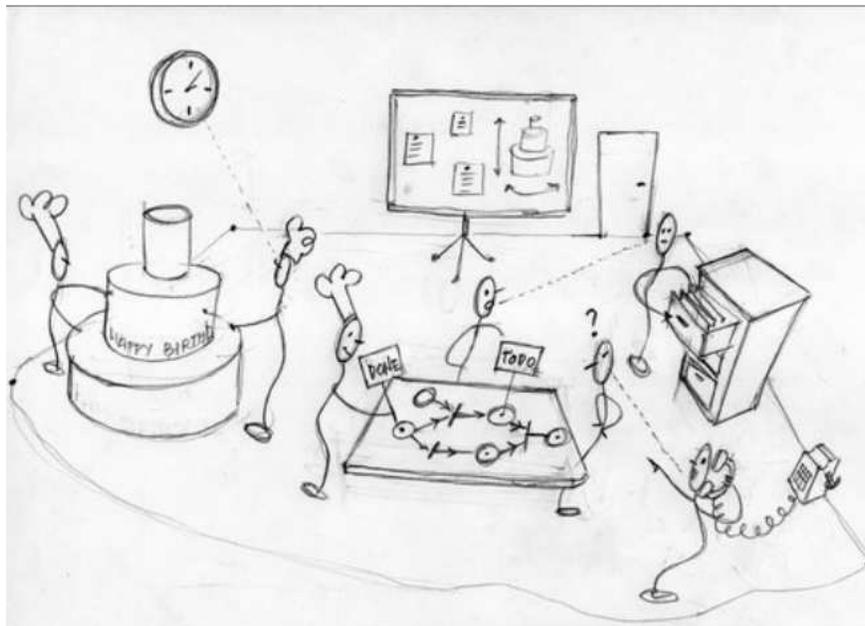
tes en esta tarea: cada usuario dispondrá de un asistente personal para interactuar con la habitación. El énfasis aquí está en la comunicación basada en actos de habla, los protocolos de coordinación descentralizados, los artefactos como herramientas de mediación y las arquitecturas que permiten ejecutar a los agentes de manera distribuida.

El capítulo ocho introduce la dimensión organizacional que permite que los agentes adopten diferentes roles y se organicen en equipos de trabajo para la consecución de sus metas bajo ciertas normas. Estos elementos se describen usando un lenguaje basado en XML que provee Moise, la capa organizacional de JaCaMo. Al igual que los artefactos, los agentes pueden crear organizaciones en tiempo de ejecución. El capítulo nueve aplica estos conceptos para mejorar la coordinación de la habitación inteligente desarrollada en los capítulos siete y ocho. Los agentes pueden ahora adoptar los roles de asistente o controlador y votar entre ellos para decidir la temperatura adecuada.

El capítulo diez discute la interacción con otras tecnologías que

es muy interesante dado el uso de Java. Es posible encapsular los objetos y métodos de otros sistemas en acciones y artefactos para el uso de los agentes, por ejemplo, algoritmos de aprendizaje automático (Weka). También es posible ejecutar a los agentes en otras infraestructuras como Jade o ROS.

El capítulo once cierra el libro situando la perspectiva MAOP en la tradición y el futuro de la Inteligencia Artificial (IA), donde estamos ante la materialización de lo que Allen Newell llamó el nivel de conocimiento y el nivel social de los sistemas computacionales. También se discuten las importantes contribuciones de la MAOP desde la perspectiva de Ingeniería de Software. Por lo anterior, me parece que es una lectura ampliamente recomendable para cualquier estudioso de la IA, en particular para aquellos interesados en aplicaciones que operan en ambientes abiertos, dinámicos y difíciles de predecir. El texto también puede usarse para las prácticas de un curso de Sistemas Multi-Agente con duración de un semestre.*



Representación de un sistema multiagente. Imagen tomada del Libro.



Si te cuidas **tú**, nos cuidamos **todos**

Todos podemos hacer algo para mitigar y contener la expansión de las enfermedades. Lo primero siempre es entender qué son, cómo se transmiten y cómo afectan.

En este caso, se trata del coronavirus SARS-COV2. Apareció en China en diciembre pasado y provoca una enfermedad llamada COVID-19, que se ha extendido por el mundo y fue declarada pandemia global por la Organización Mundial de la Salud.

Medidas de prevención



LAVA TUS MANOS
CON AGUA Y JABÓN



ACUDE AL MÉDICO SOLO EN
UNA URGENCIA



TOSE O ESTORNUDA
EN LA PARTE INTERNA
DE TU CODO

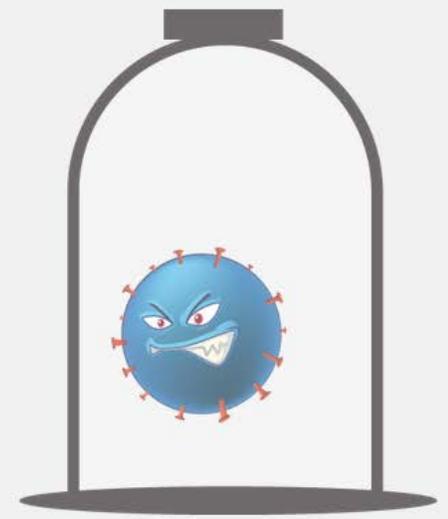


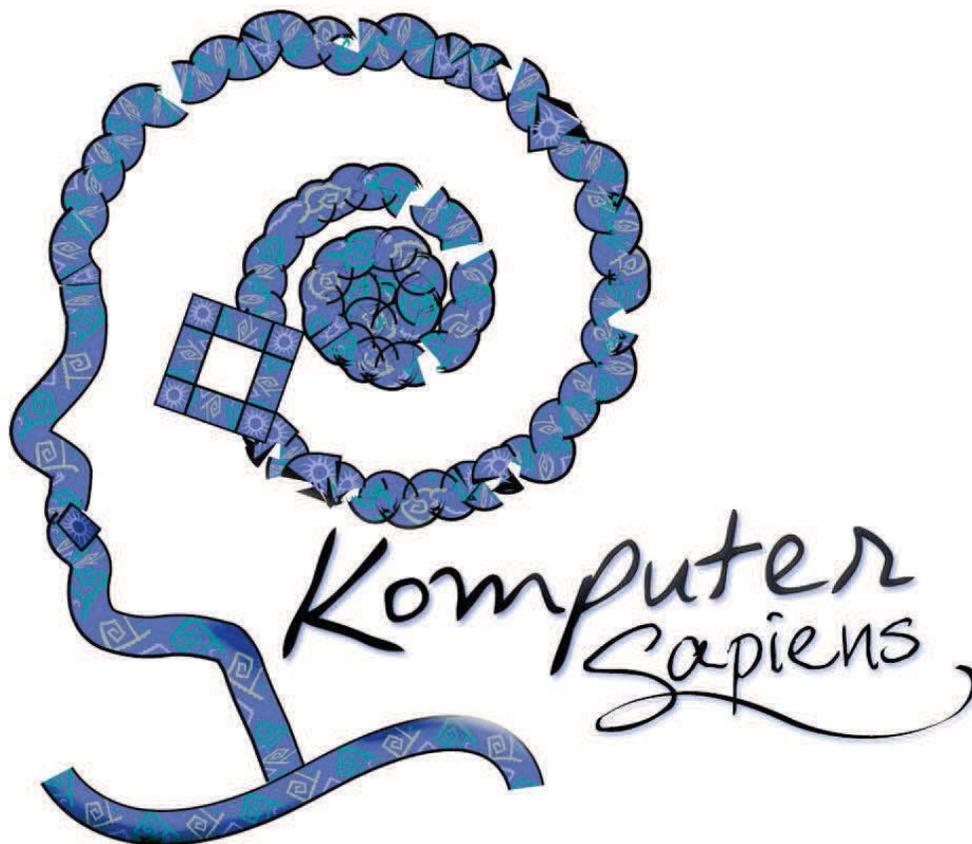
NO DIFUNDAS NOTICIAS
FALSAS

Atendiendo las normas de la Nueva Normalidad y cuidándonos unos a otros podremos salir adelante.

¡SI AISLAMOS AL VIRUS, LO VENCEREMOS!

Información tomada de: <https://coronavirus.gob.mx>





¡Publique en Komputer Sapiens!



Komputer Sapiens solicita artículos de divulgación en todos los temas de Inteligencia Artificial, dirigidos a un amplio público conformado por estudiantes, académicos, empresarios, tomadores de decisiones y consultores. Komputer Sapiens es patrocinada por la SMIA, la Sociedad Mexicana de Inteligencia Artificial



www.smia.org.mx

Instrucciones para autores e información general: <http://www.komputersapiens.org>
Síguenos en las redes sociales: www.facebook.com/Komputer.Sapiens, twitter.com/KomputerSapiens

