

Aprendizaje Automático: Una Contribución a la Investigación Operativa

Alvaro Talavera
Departamento de Ingeniería
Universidad del Pacífico
Lima, Peru
ag.talaveral@up.edu.pe

Ana Luna
Departamento de Ingeniería
Universidad del Pacífico
Lima, Peru
ae.lunaa@up.edu.pe

Title— Machine Learning: A Contribution to Operational Research

Abstract—In this work, we integrate computational techniques based on machine learning (ML) and computational intelligence (CI) to conventional methodologies used in the Operational Research (OR) degree course for Engineers. That synergy between those techniques and methods allows students to deal with decision-making complex problems. The primary goals of this research work are to present potential interactions between the two computational fields and show some examples of them. This is a contribution to engineering education research where we present how ML techniques, such as neural networks, fuzzy logic, and reinforcement learning are integrated through applications in an OR course, being able to increase the approach of more complex problems in a simpler way compared to traditional OR methods. The current paper is a different proposal for OR courses that uses the symbiosis between mathematical models employing computer simulations, CI and different hybrid models.

Index Terms— operational research, machine learning, optimization, hybrid models.

I. INTRODUCCIÓN

Este artículo es la extensión de un trabajo de investigación presentado en la conferencia EDUNINE 2019 [1], que fue reconocido como uno de los mejores en el III Congreso Mundial de Educación en Ingeniería de IEEE - EDUNINE2019 (III IEEE World Engineering Education Conference).

Los temas que amplían la versión original son la descripción detallada y la presentación de algunas aplicaciones de la técnica estructurada conocida como Proceso de Jerarquía Analítica (PJA), y cómo se integra con la inteligencia computacional (IC), específicamente con el aprendizaje automático (AA), dentro del curso de Investigación Operativa (IO). Además, mostramos y describimos algunas técnicas de AA que amplían, en gran medida, la posibilidad de incorporar y resolver problemas complejos al abordarlos con métodos que pertenecen al área de IC y no a partir de las técnicas comúnmente utilizadas en

IO, como la optimización lineal y no lineal.

También incorporamos el uso de Aprendizaje por Refuerzo (AR), la cual es un área de AA, como alternativa a las restricciones que ofrece la técnica de programación dinámica (PD).

Es importante destacar que se han revisado, evaluado y agregado más del 30% de referencias sobre los temas que incorporamos en esta nueva versión.

Actualmente, los programas académicos del curso de IO incluyen algunas técnicas de análisis, minería de datos y aprendizaje automático e inteligencia artificial. Lo mismo sucede en los programas de posgrado (p. ej. en el Centro de Investigación de Operaciones del MIT, en Ingeniería Industrial e Investigación de Operaciones de la Universidad de Columbia - NY), y en cursos de pregrado, tales como el de Investigación de Operaciones y Ciencia de la Gestión (Universidad de California-Berkeley) y el de Investigación de Operaciones e Ingeniería Financiera (Universidad de Princeton). Estas herramientas son esenciales ya que actualmente, el análisis de datos es un procedimiento habitual y necesario dentro de las empresas que buscan patrones que ayudan a la toma de decisiones. Por lo tanto, es imprescindible saber explorar y manipular datos, así como construir modelos y conocer algoritmos complejos para realizar inferencias entre las variables estudiadas.

El gran desafío que enfrenta el educador de estos tiempos es cómo preparar a los estudiantes para lidiar con este nuevo tipo de habilidades necesarias y esenciales que se requieren para solucionar los problemas de negocios de hoy en día. Una posible forma de resolver este dilema es dividir el proceso de aprendizaje en dos etapas distintas: (i) en esta fase se capacita a los alumnos en la selección, el pre-procesamiento (limpieza de datos) y la obtención de transformación de los datos, previa codificación [2]. Estas etapas pertenecen al proceso de Descubrimiento del Conocimiento en Bases de Datos (o KDD) (Fig. 1), las cuales se suelen enseñar en cursos previos a IO y en cursos iniciales de Ciencias de la Computación. En la etapa (ii) se instruye al alumno a estudiar y aplicar algoritmos de AA [3, 4]; que pueden integrarse a los modelos utilizados en IO.

En este artículo nos centraremos principalmente en esta segunda etapa, por lo que proponemos introducir algoritmos de AA en el análisis de toma de decisiones y aplicaciones dentro del curso de IO.

II. EL CONTEXTO DEL ESTUDIO

En esta sección, presentamos el perfil de la nueva generación de estudiantes que están atravesando por la 4^a Revolución. Además, describimos brevemente los roles de la IO y del AA que forman parte de un programa en un curso de la carrera de Ingeniería. Luego resaltamos la integración de ambos subcampos para lograr la sinergia deseada.

A. Perfil de los estudiantes de la Generación Z

El advenimiento de la cuarta revolución industrial (revolución 4.0) incorpora y adopta las computadoras y la automatización de la tercera revolución y la mejora con sistemas inteligentes y autónomos alimentados por datos y aprendizaje automático [5]-[8]. Entonces, esta nueva etapa trae consigo desafíos técnicos desde la perspectiva curricular; los cursos y programas de capacitación deben actualizarse y satisfacer los nuevos requisitos tecnológicos, sus contenidos y sus métodos deben preparar a los futuros profesionales y concientizarlos de la importancia de adquirir estas competencias, preparándolos para la era de la transformación.

Los estudiantes universitarios actuales pertenecen a la generación Z (personas que nacieron a mediados de los 90 y principios de los 2000) y enfrentan el proceso de transformación digital en un entorno de innovación constante tanto a nivel interno como externo. Esos estudiantes se caracterizan por ser autodidactas, regulan sus conocimientos con aprendizaje informal, son creativos y están permanentemente expuestos a la información. Por otro lado, el diseño del plan de estudios de ingeniería debe satisfacer las necesidades del sector productivo, de modo que los graduados tengan bases sustanciales y sólidas que faciliten su presencia activa en el mercado laboral, teniendo en cuenta la tendencia y los requisitos de la industria [9, 10]. Algunas de las demandas actuales pueden abordarse a través de técnicas aprendidas en cursos como IO y AA; ambos campos son interdisciplinarios y utilizan herramientas matemáticas, técnicas de estadística, algoritmos, conceptos de economía y recursos informáticos [11, 12]. Es importante tener en cuenta que los requisitos mínimos para que los estudiantes asistan al curso de ingeniería propuesto en este trabajo son conocer conceptos de estadística inferencial, análisis matricial y haber tenido contacto con técnicas básicas de programación.

B. Investigación Operativa

La investigación de operaciones (IO) es una herramienta



Fig. 1: Proceso del Descubrimiento del Conocimiento en Bases de Datos

fundamental para la teoría de la decisión con incertidumbre, y resolución de problemas de pronóstico y optimización [13] - [16]. Este método analítico de resolución de problemas y toma de decisiones emplea técnicas cuantitativas basadas en métodos científicos rigurosos (Fig. 2).

Según [15], el término "operaciones" se refiere a la resolución de problemas relacionados con la forma de llevarlos a cabo y con la coordinación de las operaciones dentro de una organización o empresa. Por otro lado, el término "investigación" se refiere a lo que se debe hacer en la investigación científica y sistemática tradicional.

En uno de los libros más consultados por los estudiantes de pregrado y con una base sólida académica [16], el autor define a la IO como una ciencia y un arte en sí misma, porque utiliza un conjunto de técnicas matemáticas y el éxito de la solución depende de la creatividad y la experiencia del equipo. Los beneficios de usar métodos de IO en muchas aplicaciones y diferentes campos (militar, planificación, organizacional, etc.) son evidentes, además existen muchas revistas científicas, conferencias y sociedades que se abocan al estudio de IO.

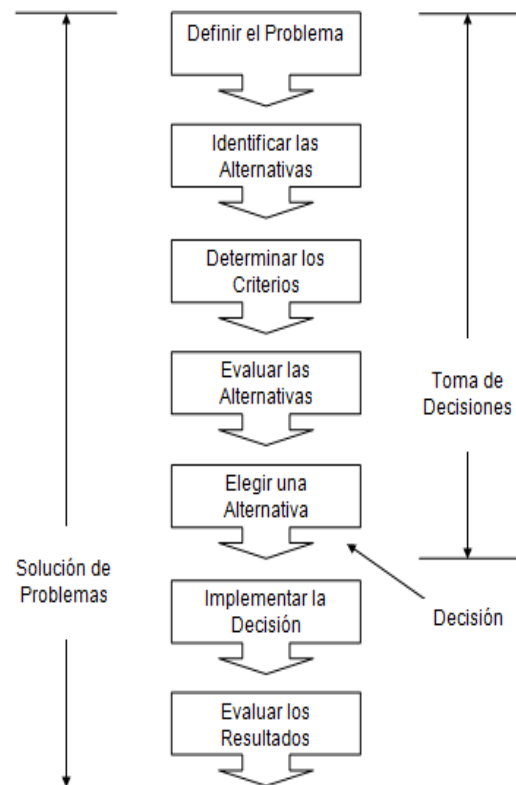


Fig. 2: Diagrama que relaciona la resolución de problemas y la toma de decisiones en IO, el cual muestra que el proceso de toma de decisiones es una parte de la solución de problemas [13]

C. Aprendizaje Automático

Dentro del campo de ciencias de la computación e ingeniería, la rama de la inteligencia artificial, conocida con el nombre de Aprendizaje Automático (AA) ha sido una de las más utilizadas en los últimos años debido al amplio campo de aplicación que tiene, incluido el procesamiento de imágenes, la clasificación de la secuencia de ADN, en

análisis financiero como es el caso de la detección de fraude de tarjetas, en algoritmos de motores de búsqueda, entre muchos otros [17, 18]. Las técnicas de AA requieren una base matemática moderada, utiliza álgebra lineal, estadística y optimización para desarrollar técnicas que permitan a las computadoras (máquinas) la capacidad de "aprender" a partir de los datos, utilizando algoritmos computacionales sofisticados. La palabra aprendizaje debe entenderse como la obtención de cualquier programa o método computacional que mejore el desempeño en algunas tareas a través de la experiencia (Fig. 3).

En el libro clásico de Tom Mitchel [4], el AA se define formalmente como un programa de computadora que "aprende" de la experiencia E de una tarea T determinada con una medida de rendimiento P , proporcionada por una función específica.

El AA se divide en tres tipos de aprendizaje: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo [19], que tienen diferentes enfoques en aplicaciones como clasificación, predicción (con regresión y la predicción a través de series temporales), agrupación o segmentación, estimación probabilística por procesos de Markov (aprendizaje por refuerzo), optimización (por medio de computación evolutiva), y finalmente sistemas de inferencia difusos, que son de importancia relevante para la teoría de las decisiones cuantitativas y la investigación operativa.

Actualmente, y en algunas universidades, dentro de los cursos de IO se ha comenzado a integrar métodos computacionales cuantitativos de AA e inteligencia artificial (IA), mejorando así su aplicación en áreas tales como la asistencia sanitaria [20], la previsión y la optimización [21].

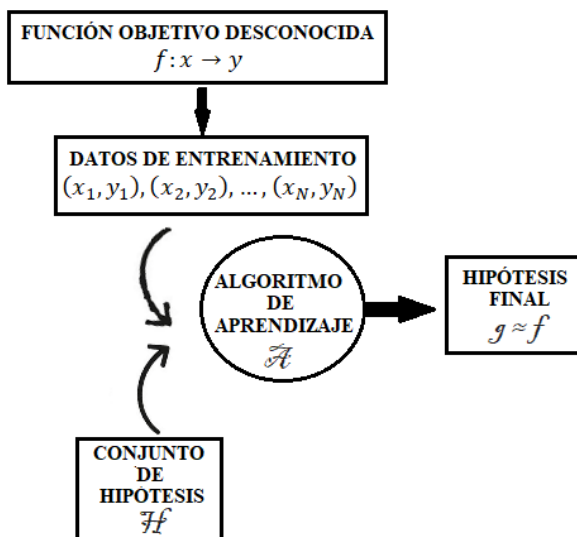


Fig. 3: Esquema general con los elementos del AA [2]

Por otro lado, uno de los desafíos a los que se enfrentan los educadores cuando intentan utilizar las técnicas de AA en los cursos IO es la falta de conocimiento computacional por parte de los estudiantes de pregrado. Afortunadamente, los lenguajes de programación como Python, Matlab, R y RapidMiner permiten una forma más fácil y amigable de introducir la programación, ya que todos poseen tutoriales, cajas de herramientas o paquetes disponibles (muchos de

manera gratuita) y simples de usar por cualquier estudiante universitario con una base mínima de conocimientos de informática. Entonces, queda como uno de los objetivos del curso enseñar a los estudiantes las técnicas y nociones básicas para la comprensión del funcionamiento de los métodos de clasificación tales como los k-vecinos más cercanos (KNN), el clasificador lineal básico, Naive Bayes, los algoritmos simples de agrupamiento, y la extracción de reglas de asociación e identificación de patrones frecuentes.

Una manera de introducir los elementos principales de la teoría del AM se muestra en la Fig. 3, donde el método consiste en construir una función aproximada g (construida a partir de un conjunto de hipótesis) que relacione un conjunto de datos de entrada X y de salida Y , utilizando un algoritmo de aprendizaje A .

La IO utiliza una gran cantidad de datos para proporcionar soporte para los procesos de toma de decisiones y, a veces, se considera parte de la IA, que incluye el AA. Sin embargo, se consideran dos ramas diferentes para la toma de decisiones dentro del campo de la ciencia de datos.

El AA tiene una gran atracción dentro de las organizaciones empresariales porque ayuda a comprender cómo manejar la enorme cantidad de datos, presentando una ventaja en comparación con las técnicas convencionales de IO, donde comienza el modelado de procesos complejos. Además, el AA aborda cualquier problema sólo a partir de los datos, sin ideas preconcebidas y esto a menudo no es así en la IO.

Una solución posible e inteligente es integrar IO en proyectos de AA, porque los datos de una empresa son generalmente complejos y de gran importancia, y sin duda constituyen un entorno más realista para comenzar el abordaje de los proyectos de IO, dejando de lado parte de la complejidad e incorporando la capacidad para crear soluciones pequeñas y escalables en el área de negocios.

La perspectiva errónea del AA y la IO como disciplinas competidoras debe dejarse de lado. Por el contrario, sería una solución acertada y potencial generar una multidisciplina entre ambas para cubrir sus dominios e integrarlos en los planes de estudio académicos.

El problema central es entonces reducir la ausencia de metodologías y proponer casos de estudio que integren la IO y el AA; y así poder incorporar la Teoría de la Decisión Multicriterio (Proceso de Jerarquía Analítica, PJA), el Proceso Analítico en Red (ANP), la Ponderación Lineal (Scoring) [22], métodos para la toma de decisiones de modelado de incertidumbre, procesos de Markov y optimización [23, 24], simulaciones de Monte Carlo, predicción a través de series temporales, sistemas de inferencia difusos, mediciones difusas no aditivas, redes neuronales para el pronóstico de series de tiempo, técnicas de aprendizaje por refuerzo y computación evolutiva.

El objetivo principal del presente estudio es lograr la integración entre las técnicas utilizadas en un curso avanzado de IO, AA e IA a través de los modelos híbridos.

III. PROPUESTA METODOLÓGICA

El curso de Investigación Operativa introduce a los estudiantes a usar modelos matemáticos, estadística aplicada y algoritmos computacionales simples; orientados a la toma de decisiones bajo riesgo e incertidumbre. Los temas estudiados son árboles de decisión, PJA para análisis

multicriterio, cadenas de Markov, simulación de Monte Carlo y pronósticos. El conocimiento de esas herramientas ayuda a los estudiantes a analizar y a tomar decisiones utilizando técnicas cuantitativas y probabilísticas, además de simular posibles escenarios, modelar incertidumbres, evaluar opciones con múltiples criterios y hacer estimaciones de variables relevantes en las organizaciones. Es en este curso donde es posible agregar técnicas de AA teniendo en cuenta el objetivo y el programa de estudios.

En particular, el PJA es muy utilizado para la toma de decisiones en aplicaciones de ingeniería. Es un enfoque que emplea criterios múltiples para la resolución de problemas complejos [25]. Con el método PJA, los estudiantes deben aprender cómo seleccionar los datos pertinentes y confiar en los juicios de los expertos para dar un orden o escala de prioridad y clasificar las alternativas. El PJA se ha utilizado en admisiones de estudiantes, en el ascenso de escala del personal militar, en decisiones de contratación de personal, en deportes para predecir el equipo ganador, en varias aplicaciones militares y políticas, e incluso para determinar el mejor sitio de reubicación debido a un terremoto, entre otros [26]. Pero lo más importante es que el uso de la teoría PJA abre el camino y permite a los profesores integrar el AA en el curso de IO a través de sistemas de lógica difusa. Estos métodos se utilizan en aplicaciones informáticas y de análisis de datos, después de la unidad de toma de decisiones multicriterio (MCDM). El dominio de la lógica difusa no se limita a la ingeniería de control, ya que los sistemas de inferencia difusa (FIS) incorporan sistemas complejos de toma de decisiones que incluyen incertidumbre y proporcionan reglas de decisión difusas [27, 28]. En el caso particular de IO, es posible crear indicadores de rendimiento basados en variables medidas. Durante el curso, utilizamos un ejemplo que requiere la técnica PJA para elegir el hotel deseado para vacacionar considerando diferentes parámetros, como precio, accesibilidad, temporada, instalaciones, entre otros. De esta manera, fue posible obtener y cuantificar diferentes puntajes en el intervalo (0,1), siendo el número 1 la mejor alternativa. Por otro lado, si el objetivo es evaluar un hotel visitado con anterioridad, se debe utilizar otra técnica. Este último problema, implica incertidumbre en el proceso de decisión, ya que depende de varias variables, y muchas de ellas son cualitativas. Por esta razón, utilizamos sistemas difusos [28, 29], que trazan variables lingüísticas no lineales, colocando como resultado final un número real.

Otro ejemplo más simple y directo en el que también usamos sistemas difusos es el empleo de las variables instalación (referente a las instalaciones del hotel) y el nivel de servicio para obtener una calificación de un hotel en particular (Fig. 4). En la Fig. 5, mostramos la relación no lineal (difusa) entre las variables de entrada (instalación y servicio) y la salida (calificación de hotel).





Fig.4: Reglas de un sistema de inferencia difusa

Dos de las técnicas más utilizadas en IO son la optimización lineal y no lineal. Actualmente, hay cursos de IO que sólo se centran en el aprendizaje y la especialización de este tipo de técnicas. Una buena definición de "optimización" se encuentra en [30], y es *resolver un problema de decisión complejo al tener una selección de valores para varias variables interrelacionadas que buscan como meta encontrar la función objetivo, que está diseñada para cuantificar el desempeño de la calidad de la decisión*. Esta definición general y compleja al mismo tiempo, abre una gran cantidad de aplicaciones que forman parte de nuestra vida cotidiana en la industria, transporte, salud, energía, agricultura, finanzas, gestión pública, etc. [31]. Sin embargo, a medida que los problemas se vuelven más difíciles, estas técnicas también se intensifican en sofisticación y se necesita un modelo matemático robusto para hallar la expresión de la ecuación de la función objetivo, además que el tiempo computacional para la solución del problema aumenta considerablemente. Mientras tanto, las técnicas de optimización de AA tienen la ventaja de prescindir de una función explícita, como la computación evolutiva, un subcampo de la inteligencia artificial; y la técnica de enjambre, donde su aplicación en problemas complejos y discretos es prominente.

Siguiendo la línea de optimización, otra técnica avanzada que generalmente se usa en IO es la programación dinámica (PD), que es un método matemático-computacional que se emplea para la resolución de problemas donde se requiere conocer las políticas óptimas en una serie de decisiones que se toman secuencialmente, proporcionando un procedimiento sistemático para encontrar la combinación de decisiones que maximiza la efectividad total. La PD funciona con un conjunto de algoritmos que se utilizan para calcular las políticas óptimas dado un modelo perfecto del entorno que se ajusta a un proceso de decisión de Markov [32, 33]. El problema se divide en etapas y cada una de ellas está vinculada a través de cálculos recursivos. Las aplicaciones de este método son diversas, como la



planificación principal de ventajas de decisión, etc. Por otro lado, su principal desventaja es el costo computacional. En ese sentido, una metodología de AA muy conveniente es el aprendizaje por refuerzo o Reinforcement Learning (RL), donde un agente aprende el comportamiento a través de interacciones de prueba y error en un entorno dinámico. RL es el aprendizaje que relaciona situaciones (estados) con acciones para maximizar alguna señal de refuerzo, superando las limitaciones que presenta la PD. En

publicaciones recientes y en conferencias de IO, se incorporan aplicaciones que emplean el RL [34].

Algunos trabajos de investigación, como el de la Ref. [35], aplican aprendizaje por refuerzo de múltiples agentes a un conjunto de problemas de optimización, los cuales también pueden ser enseñados en un curso avanzado de IO. Específicamente, este tipo de técnicas de AA trata de proporcionar soluciones sub-óptimas al problema de planificación y programación de operaciones, que está entre los problemas de optimización combinatoria más difíciles en la informática y en la IO, en donde los trabajos se asignan según los recursos en momentos particulares. El autor de [35] propone enfrentarlo como un problema de decisión secuencial y obtuvo mejores resultados en comparación con las técnicas tradicionales, teniendo la ventaja de tener un calendario de aprendizaje y políticas en materia de tiempo, para luego poder generalizarlas en un contexto distinto.

En un trabajo de investigación recientemente publicado [36], se emplea el aprendizaje profundo por refuerzo para la optimización de la programación de producción global, logrando una visión de la Industria 4.0 con integración completa de la red, el control de producción; y la toma de decisiones descentralizada.

En general, el RL aumenta significativamente las aplicaciones en el curso de IO en áreas como problemas de juegos, simuladores, planificación de refineries, sistemas multiagentes, redes eléctricas inteligentes, etc. [33], [37, 38].

Otra estrategia en la que logramos la sinergia entre la IO y el AA fue la inserción de modelos computacionales de redes neuronales (perceptrón multicapa y retropropagación) en la unidad del curso correspondiente al análisis de regresión multivariante. Para llevar a cabo este procedimiento, sólo usamos regresiones multivariantes simples, la motivación hacia los estudiantes surge al plantear un problema no lineal cuya resolución se lleva a cabo con la técnica recientemente aprendida. Es el primer acercamiento de los estudiantes a los sistemas computacionales de redes neuronales, de esta manera, los alumnos pueden obtener un mejor rendimiento con estas técnicas en comparación con la regresión no lineal multivariable. Luego, surgirán nuevos modelos de aproximación no lineal, con aplicaciones predictivas y también de clasificación [4], [19], [39].

Por otro lado, el costo de insertar los modelos de redes neuronales en un curso de IO, restringe el hecho de sólo poder abordar 3 métodos de pronósticos utilizando suavizamiento exponencial y estacional (como el método de pronóstico de triple exponente suavizante Holt-Winters). Por lo tanto, la reestructuración propuesta en este documento tiene un impacto en el plan de estudios porque antes de la modificación sólo se enseñaban métodos estacionales aditivos y multiplicativos.

En la unidad de pronóstico, se tratan algoritmos clásicos como el método de Promedio Móvil Simple, suavizamiento exponencial, método de Holt-Winters y modelos clásicos como ARIMA. Asimismo, esa unidad es útil para poder incluir pronósticos de series de tiempo con redes neuronales [16]. Además, el uso de algoritmos de aprendizaje automático, como las redes neuronales, hacen una buena sinergia con los métodos de regresión de la investigación operativa, especialmente en el caso de los pronósticos.

IV. RESULTADOS

Después de incorporar el AA en el curso IO, ocho estudiantes universitarios presentaron artículos científicos en el MIT Scale Latin America 2018 organizado por el Centro de Transporte y Logística del MIT (CTL) [40, 41]. Sus trabajos pasaron el proceso de revisión por pares y fueron invitados a presentar sus respectivas investigaciones (relacionadas con los desafíos de la cadena de suministro, la asignación de presupuesto en logística humanitaria para mejorar las estrategias de prevención, sistemas PJA y difusos), recibiendo evaluaciones de profesionales y miembros científicos de la comunidad de la cadena de suministro. En todos los casos, los comentarios de la audiencia especializada fueron muy alentadores. También participaron en varias sesiones de la Conferencia, dentro de los tópicos de logística humanitaria, gestión de la cadena de suministro para pequeñas empresas y operaciones minoristas, logística humanitaria y operaciones de socorro en casos de desastres, logística urbana y operaciones de última milla; y sostenibilidad en la cadena de suministro.

Los artículos [40-42] son productos del curso IO y utilizan algunas técnicas de AA. El trabajo de investigación [40] presenta una metodología para asignar el presupuesto óptimo en múltiples proyectos para la prevención de desastres naturales en las regiones del norte del Perú teniendo en cuenta el grado de vulnerabilidad de la localidad, el nivel de pobreza, la cantidad de población, y el nivel de ejecución del gasto durante los desastres. Utilizaron tanto la herramienta de análisis de multi-criterios, como así también el PJA. Posteriormente, los autores implementaron un algoritmo de lógica difusa para obtener el presupuesto para cada región.

En el caso del artículo [41], se introduce un método para la ubicación óptima de una nueva unidad de negocios de una empresa en particular, utilizando técnicas de PJA. Luego, incorporaron un método de lógica difusa para establecer las tarifas de los servicios de acuerdo con los criterios establecidos.

Otros dos estudiantes universitarios presentaron un artículo científico en el XXIV Congreso Internacional de Ingeniería Eléctrica, Electrónica e Informática (INTERCON 2017), llevado a cabo en la Universidad Nacional de San Antonio Abad en Cusco, Perú [42]. En su trabajo, utilizaron el PJA y los sistemas de inferencia difuso, que fueron técnicas aprendidas en el curso de IO. El objetivo principal de este documento es proponer una metodología basada en el PJA y los FIS, para obtener una mejor selección en el sistema de planificación de recursos empresariales (ERP). Una compañía en particular impuso los criterios para la selección y los ERP basados en la información de algunos proveedores, entonces para seleccionar el ERP más apropiado, se usó PJA, luego, se evaluó el ERP utilizando un FIS para saber si cumplía con el desempeño financiero y operativo del negocio. Finalmente, un nuevo FIS fusiona estos resultados en uno único, que se llama "nivel de aceptabilidad". La metodología propuesta trata de cuantificar la subjetividad que implica una adquisición de ERP por parte de una empresa.

Finalmente, una de las contribuciones más importantes de la inserción de los modelos computacionales en el curso, fue la publicación de un artículo en el cual un estudiante trabajó usando redes neuronales artificiales (ANN) como herramienta de pronóstico en el área de contaminación atmosférica [43]. El artículo científico muestra los

resultados preliminares del monitoreo y la estimación de contaminantes del aire donde se utilizaron sensores electroquímicos de bajo costo, portátiles, inalámbricos y geo-localizables para capturar niveles confiables de contaminación en tiempo real. Además, para la predicción de los niveles de CO₂ y SO₂, se aplicaron y validaron algoritmos de inteligencia computacional con datos experimentales.

Los resultados obtenidos de la implementación de varias técnicas de ML en el curso de IO también se reflejaron en las encuestas semestrales realizadas a los estudiantes y promovidas por el Departamento de Gestión del Aprendizaje de la Universidad. Las mismas proporcionaron comentarios positivos y un gran interés por parte de los estudiantes debido al aprendizaje y a la aplicación de metodologías de vanguardia, lo que indica un alto nivel de satisfacción con el curso.

V. CONCLUSIONES Y FUTURA INVESTIGACIÓN

La investigación operativa y el aprendizaje automático pueden beneficiarse uno del otro. Una de las ventajas significativas es que esta sinergia aumenta las aplicaciones del curso de IO, en particular, en la ciencia de datos mediante el uso del aprendizaje automático. De esta forma, integramos técnicas de inteligencia computacional en IO para enfrentar de manera óptima las aplicaciones reales en los problemas de toma de decisiones.

Actualmente, la tendencia es aumentar las unidades metodológicas de minería de datos en los últimos cursos de grado de la carrera de Ingeniería. Las estrategias para incorporar los objetivos básicos, las técnicas y las aplicaciones de AA en IO que se muestran en este artículo demostraron ser muy prometedoras; motivaron el compromiso y el desempeño de los estudiantes.

Por otro lado, el interés en el aprendizaje automático continúa creciendo, tanto en la academia como en la industria, y la mayoría de los problemas de aprendizaje automático son herramientas potenciales para el análisis de los procesos de toma de decisiones. Además, las carreras de negocios no son ajenas a los avances del big data y la inteligencia artificial, por lo que elegir las técnicas de aprendizaje automático correctamente, de acuerdo con el objetivo del Departamento de Ingeniería, es un desafío para los educadores.

Debido a la naturaleza escalable de la investigación propuesta, el trabajo futuro es incursionar en la combinación IO-AA incorporando el aprendizaje por refuerzo en las cadenas de Markov, considerando los requisitos mínimos necesarios por parte de los estudiantes para afrontar este tipo de curso. Por lo tanto, y debido a los conocimientos computacionales necesarios, la audiencia potencial debería pertenecer a un ciclo de estudios de posgrado.


REFERENCIAS

- [1] A. Talavera, and A. Luna, "Operational Research and Machine Learning: An Engineering Course," *2019 IEEE World Conference on Engineering Education (EDUNINE)*, Lima, Peru, 2019, pp. 1-5.
- [2] J. Han, J. Pei, and M. Kamber, *Data mining: concepts and techniques*. Elsevier, 2011.
- [3] Y. S. Abu-Mostafa, M. Magdon-Ismail and H.T. Lin, *Learning from Data*. Vol. 4. New York, NY, USA, AMLBook, 2012.
- [4] T. M. Mitchell, *Machine Learning*. McGraw Hill, 1997, pp. 367-390.
- [5] F. Almada-Lobo. (2015). The Industry 4.0 revolution and the future of Manufacturing Execution Systems (MES). *Journal of Innovation Management*. 3(4), pp. 16–21.
- [6] H. Lasi, P. Fettke, H. G. Kemper, T. Feld, and M. Hoffmann. (2014). Industry 4.0. *Business & Information Systems Engineering*. 6(4), pp. 239-242.
- [7] M. Rühlmann, M. Lorenz, P. Gerbert, M. Waldner, J. Justus, P. Engel, & M. Harnisch. (2015, Apr. 9). Industry 4.0: The future of productivity and growth in manufacturing industries. *Boston Consulting Group*. 9(1), pp. 54-89. Available: <https://www.zvw.de/media.media.72e472fb-1698-4a15-8858-344351c8902f.original.pdf>
- [8] A. Gilchrist, *Industry 4.0: the industrial internet of things*. Apress, Springer, 2016.
- [9] K. Schuster, K. Groß, R. Vossen, A. Richert, and S. Jeschke, "Preparing for industry 4.0 – collaborative virtual learning environments in engineering education," in *Engineering Education 4.0*, Springer, Cham, in *The International Conference on E-Learning in the Workplace 2015*, New York, pp. 477-487.
- [10] A. S. Phadke, and S. S. Kulkarni. (2018). Use of Network Model for Analysis of Curriculum and its Mapping to Program Outcomes, *Journal of Engineering Education Transformations*. 31(3), pp. 30-34.
- [11] J. A. White. (1991). An existence theorem for OR/MS. *Operations Research*. 39(2), pp. 183-193. Available: <https://doi.org/10.1287/opre.39.2.183>
- [12] S. Meisel, D. Mattfeld. (2010). Synergies of operations research and data mining, *European Journal of Operational Research*. 206(1), pp.1-10.
- [13] D. Anderson, D. J. Sweeney, T. A. Williams et al., *An Introduction to Management Science: Quantitative Approaches to Decision Making*, Cengage Learning EMEA, 2018.
- [14] S. C. Albright and W. L. Winston. (2009). *Practical Management Science*. (3rd ed.). South-Western/Cengage Learning.
- [15] F. S. Hillier and G. J. Lieberman. (2015). *Introducción a la Investigación de Operaciones*, vol. 1. Novena edición. McGraw-Hill.
- [16] H. A. Taha. (2012). *Introducción a la Investigación de Operaciones*, Novena edición, Pearson Educación.
- [17] P. K. Chan, and S. J. Stolfo. (1998). Toward Scalable Learning with Non-Uniform Class and Cost Distributions: A Case Study in Credit Card Fraud Detection. In *KDD*. pp. 164-168.
- [18] M. Egmont-Petersen, D. de Ridder, and H. Handels. (2002). Image processing with neural networks — a review. *Pattern recognition*, 35(10), pp. 2279-2301.
- [19] S. Haykin. (2008). *Neural Networks and Learning Machines*. (3rd ed.). Pearson.
- [20] L. Li, et al. (2004). Data mining techniques for cancer detection using serum proteomic profiling, *Artificial intelligence in medicine*. 32(2), pp. 71- 83.
- [21] M. Chui, J. Manyika, M. Miremadi, N. Henke, R. Chung, P. Nel, and S. Malhotra. Notes from the AI frontier: Insights from hundreds of use cases. DISCUSSION PAPER APRIL 2018. McKinsey Global Institute (MGI).
- [22] R. T. Clemen and T. Reilly. (2013). *Making hard decisions with Decision Tools*. (3rd ed.). South-Western Cengage Learning, USA.
- [23] R. A. Howard. (2012). *Dynamic probabilistic systems: Markov models*, vol. 1, John Wiley & Son, INC. USA.
- [24] A. E. Abbas, and R. A. Howard. (2015). *Foundations of decision analysis*. Pearson Higher Ed. England.
- [25] E. Triantaphyllou, and S. H. Mann. (1995). Using the analytic hierarchy process for decision making in engineering applications: some challenges. *International Journal of Industrial Engineering: Applications and Practice*. 2(1), pp. 35-44.
- [26] T. L. Saaty. (2008). Decision making with the analytic hierarchy process. *International journal of services sciences*. 1(1), pp. 83-98.
- [27] D. W. North. (1968). A tutorial introduction to decision theory. *IEEE transactions on systems science and cybernetics*. 4(3), pp. 200– 210.
- [28] H. J. Zimmermann, (1991). *Fuzzy set theory and its applications*. (2nd ed.). Boston. Kluwer Academic Publishers.
- [29] L. A. Zadeh. (1965). Fuzzy sets*. *Information and Control*. 8(3), pp. 338-353.
- [30] D. G. Luenberger, and Y. Ye. (2015). *Linear and Nonlinear Programming*. Springer Publishing Company, Incorporated.
- [31] X. S. Yang. (2018). *Optimization techniques and applications with examples*. John Wiley & Sons.
- [32] D. P. Bertsekas. (2011). "Dynamic programming and optimal control," vol. 2. (4th ed.). Belmont, MA: Athena Scientific.
- [33] R. S. Sutton and A. Barto. (2018). *Reinforcement Learning: An Introduction*. (2nd ed.). The MIT Press.
- [34] M. Schneckenerreither, and S. Haeussler, "Reinforcement Learning

- Methods for Operations Research Applications: The Order Release Problem," In: Nicosia G., Pardalos P., Giuffrida G., Umeton R., Sciacca V. (eds), vol 11331, in *International Conference on Machine Learning, Optimization, and Data Science*. Springer, Cham., 2018, September, pp. 545-559.
- [35] T. Gabel, and M. Riedmiller, "On a successful application of multi-agent reinforcement learning to operations research benchmarks," In 2007 IEEE International Symposium on Approximate Dynamic Programming and Reinforcement Learning, 2007, April, pp. 68-75.
- [36] B. Waschneck, A. Reichstaller, L. Belzner, T. Altenmüller, T. Bauernhansl, A. Knapp, & A. Kyek, "Optimization of global production scheduling with deep reinforcement learning," *Procedia CIRP*, 2018, 72(1), pp. 1264-1269.
- [37] L. P. Kaelbling, M. L. Littman, and A. W. Moore. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, pp. 237-285.
- [38] Ngoc Duy Nguyen, Thanh Nguyen, Saeid Nahavandi, "Multi-agent behavioral control system using deep reinforcement learning," *Neurocomputing*, vol. 359, pp. 58-68, 2019.
- [39] M. Inthachot, V. Boonjing, and S. Intakosum. (2016). Artificial neural network and genetic algorithm hybrid intelligence for predicting thai stock price index trend. *Computational intelligence and neuroscience*. pp. 1-8.
- [40] C. Huicho, A. Ochoa, P. Berrocal, R. Acuña and C. A. Salazar, "Assignment of the budget for prevention projects in the north central coast of Peru," presented at the MIT SCALE Latin America Conference. In Parallel Sessions Humanitarian Logistics and relief operations II. MIT Cambridge Campus, Massachusetts, U.S., 2018.
- [41] F. R. Paz Zapata, I. Bastidas and K. Marañón, "Location of a new business unit of the company Edu Holding Group and the price's fixing for the services that it will offer using the systems AHP and Fuzzy (UG)," presented at the MIT SCALE Latin America Conference. In Student Competition I (SA3). MIT Cambridge Campus, Massachusetts, U.S., 2018.
- [42] Y. López, D. Luna, A. Talavera, "Selection of ERP based on Analytical Hierarchical Process and Fuzzy Inference Systems," presented at the XXIV Congreso Internacional, INTERCON IEEE, Cusco, Perú, Aug. 2017.
- [43] A. Luna, A. Talavera, H. Navarro, and L. Cano, "Monitoring of Air Quality with Low-Cost Electrochemical Sensors and the Use of Artificial Neural Networks for the Atmospheric Pollutants Concentration Levels Prediction," In Annual International Symposium on Information Management and Big Data. 2018, September, pp. 137-150. Springer, Cham.



Alvaro Talavera es profesor investigador a tiempo completo del Departamento Académico de Ingeniería de la Universidad del Pacífico. Es ingeniero electrónico por la Universidad Católica de Santa María. Posee un Master of Science en Ingeniería Eléctrica por la Pontificia Universidad Católica de Río de Janeiro (Brasil), con especialidad en métodos de apoyo a decisión utilizando inteligencia computacional aplicada. Es Doctor (Ph.D.) en ingeniería eléctrica de la Pontificia Universidad Católica de Río de Janeiro (PUC-Rio) con especialidad en el área de procesamiento de señales, control y automatización. Posee experiencia en proyectos de investigación en el área de Petróleo, energía y negocios. Ha liderado centros de investigación en Brasil, tratando proyectos de exploración y explotación de Petróleo, caracterización de reservorios petrolíferos utilizando técnicas de inteligencia computacional. Además cuenta con experiencia en proyectos de investigación en Río de Janeiro en la gestión de riesgo en los contratos de compra de energía. Trabajó como investigador principal en el laboratorio de Inteligencia Computacional Aplicada (ICA) de la PUC-Rio, investigador del Group of Technology and Petroleum Engineering (GTEP) (Río de Janeiro). Fue además, consultor de proyectos por medio del ICA de la PUC-Rio para Petrobras S.A. en el área de gerenciamiento de reservorios y para la distribuidora de energía eléctrica de Río de Janeiro Light S.A. Es autor y coautor de varios artículos en revistas internacionales y conferencias internacionales. Es presidente de la IEEE-TEMS del capítulo de Perú. (e-mail: ag.talaveral@up.edu.pe)



Ana Luna es profesora de tiempo completo del Departamento Académico de Ingeniería de la Universidad del Pacífico e investigadora del CIUP. Es doctora y licenciada en Ciencias Físicas por la Universidad de Buenos Aires (UBA-Argentina). Cuenta con una amplia experiencia docente, ha dictado varios cursos en el área de Laboratorios Superiores en el Departamento de Física de la Facultad de Ciencias Exactas y Naturales de la Universidad de Buenos Aires, ha sido profesora interina dentro del Departamento de Física del Colegio Nacional de Buenos Aires, dependiente de la UBA. En el campo de la investigación, ha trabajado varios años en la División de Láseres Sólidos en el DEILAP, sede del CONICET. Es autora y coautora de varios artículos en revistas internacionales y conferencias internacionales. Sus áreas de especialización son cristales fotónicos, láseres sólidos, algoritmos evolutivos, multicapas, color estructural, láseres sólidos pulsados con técnicas de Q-Switch activo y pasivo. Ha sido presidenta del capítulo de la UBA de la International Society for Optical Engineering, vicepresidenta del capítulo de la UBA de la Optical Society of America y miembro de la Asociación Física Argentina, y actualmente es miembro de la IEEE. (e-mail: ae.lunaa@up.edu.pe)