

SISTEMAS COGNITIVOS ASOCIADOS AL PROCESO DE APRENDIZAJE-ENSEÑANZA DEL INGENIERO MECÁNICO: MACHINE LEARNING

Suárez-Fernández-Miranda, S.; Aguayo-González, F.; Lama-Ruiz, J.R.

*TEPO22: Diseño Industrial e Ingeniería del Proyecto y la Innovación.
Ingeniería del Diseño. Escuela Politécnica Superior. Universidad de Sevilla.*

*E-mail: ssuarez1@us.es

RESUMEN

El Ingeniero Mecánico ha de contar con una serie de Competencias adaptadas al nuevo modelo de Sistema de Producción Inteligente y Flexible, factor crítico de éxito en la Industria de Fabricación actual. El Aprendizaje Automático, o Machine Learning, relacionado con los Sistemas Cognitivos, acomete el Proceso de Enseñanza-Aprendizaje, teniendo en cuenta los Algoritmos necesarios para aprender a partir de la observación de datos. La Minería de Datos Educativos facilita la comprensión adecuada del proceso de enseñanza-aprendizaje. Resultando ser conveniente a la hora de diseñar experiencias de aprendizaje que se adapten mejor a las demandas actuales en formación para el Grado en Ingeniería Mecánica.

PALABRAS CLAVE

Ingeniero Mecánico, Fábrica Inteligente, Minería de Datos Educativos, Aprendizaje Automático, Competencias.

ABSTRACT

The Mechanical Engineer must have competencies adapted to the new model of Intelligent and Flexible Production System, a critical success factor in the current Manufacturing Industry. The Automatic Learning, or Machine Learning, related to the Cognitive Systems, undertakes the Learning Process, taking into account the Algorithms necessary to learn from the observation of data. The Educational Data Mining facilitates the adequate understanding of learning and its environment. What turns out to be convenient in designing learning experiences for the Degree in Mechanical Engineering.

KEYWORDS

Mechanical Engineer, Smart Factory, Educational Data Mining, Machine Learning, Competencies.

INTRODUCCIÓN Y OBJETIVO

A lo largo de las últimas décadas, se ha venido produciendo una progresiva adaptación de la sociedad industrial hacia una sociedad de la información y el saber. Generando un incremento en las expectativas del rol desempeñado por el Sistema Educativo para el progreso de los estudiantes del Grado en Ingeniería Mecánica y su capacidad de adaptación al nuevo contexto que estamos viviendo. En este escenario, la calidad y el rendimiento académico se han convertido en objetos de atención preferente por parte de la sociedad, poniéndose un gran empeño en mejorar el Sistema Educativo y sus prácticas. Una finalidad de la Educación tiene que ver con el individuo, con su desarrollo personal y su autonomía lograda a través del Conocimiento [1].

El perfil profesional aporta sentido de identidad a todos aquellos Ingenieros Mecánicos que van a realizar funciones específicas una vez se incorporen al mercado laboral. Además, permite relacionar la titulación con la salida profesional y la identificación de elementos formativos que han de concretarse en el currículo. Se explicita en función del análisis de funciones y tareas a llevar a cabo en el ejercicio de la profesión en el momento presente, pero también teniendo en cuenta con anticipación hacia donde se encaminan, en un futuro, los conocimientos, actitudes y habilidades que van a tener que desplegar.

La formación universitaria que se persigue tiene un carácter integrador, es aquella que forma los mejores profesionales y los mejores ciudadanos, responsables y comprometidos éticamente con la Sociedad. Esta formación integra cuatro tipos de saberes [2]:

- a. Saber técnico: que engloba la posesión de conocimientos especializados, con dominio de contenidos y tareas.
- b. Saber metodológico: que consiste en la aplicación de los conocimientos adquiridos en situaciones concretas, resolviendo de forma autónoma problemas.
- c. Saber participativo: es la orientación al grupo, la predisposición a la comunicación, la cooperación y al entendimiento interpersonal.
- d. Saber personal: consistente en saber asumir responsabilidades, tomar buenas decisiones, actuar conforme a convicciones y aprender de los errores.

En el Marco MECES las características de las cualificaciones asociadas al Grado vienen definidas según una serie de descriptores presentados en términos de resultados del aprendizaje:

- a. Adquirir conocimientos avanzados y demostrar comprensión de los aspectos teóricos, prácticos y de metodología de trabajo con profundidad y actualización del conocimiento.
- b. Aplicar conocimientos, su comprensión y capacidades de resolución de problemas en ámbitos laborales complejos o profesionales y especializados que requieren el uso de ideas creativas e innovadoras.
- c. Tener la capacidad de recopilar e interpretar datos e informaciones sobre las que fundamentar conclusiones, incluyendo, cuando sea preciso, la reflexión sobre asuntos de índole social, científica o ética.
- d. Capacidad de desenvolverse en situaciones complejas o que requieran el desarrollo de nuevas soluciones tanto en el ámbito académico como profesional.
- e. Saber comunicar de manera clara y precisa, conocimientos, metodologías, ideas, problemas y soluciones.
- f. Identificar las necesidades formativas propias y organizar el aprendizaje con autonomía en diferentes tipos de contextos.

El autoconcepto es una estructura cognitiva que contiene tres dimensiones, lo que se es, lo que se desea ser y lo que se manifiesta externamente. Lo que es el individuo frente a lo que pretende llegar a ser tiene repercusiones sobre su autoestima y constituye, al querer tender hacia la imagen ideal, una fuente de motivación [3].

El aprendizaje autodirigido desarrollado por Richard Boyatzis considera al “yo ideal” el mecanismo motivacional básico y está centrado en los deseos y esperanzas del individuo. La discrepancia entre el yo ideal y el real tiene importantes implicaciones en las conductas y las emociones [4].

La teoría cognitiva social enfatiza la interacción de factores personales, conductuales y ambientales. Estos factores se ven modificados en el trascurso del aprendizaje y han de ser reevaluados, es por ello por lo que la autoregulación se dice que es un proceso cíclico. Zimmerman, Schunk y Pintrich han hecho más comprensible el proceso de aprendizaje, incorporándose a partir de ellos los procesos metacognitivos, motivacionales y socio-contextuales, que permitieron integrar en una sola dos líneas

de investigación que se encontraban separadas, por un lado, los estudios cognitivos y por el otro los estudios sobre la motivación [5].

El Espacio Europeo de Educación Superior (EEES) impulsa la metodología de enseñanza-aprendizaje basada en una alineación entre los resultados de aprendizaje que se persiguen, las actividades formativas que se han de llevar a cabo y los métodos de evaluación adecuados. Los resultados de aprendizaje son declaraciones de lo que se espera que un estudiante conozca, comprenda y sea capaz de hacer al final de su periodo de aprendizaje [6].

El hecho de que el Ingeniero Mecánico desarrolle su labor profesional en el ámbito de la Ingeniería de Fabricación bajo enfoque Industria 4.0 implica el conocimiento relacionado con la conexión en red de máquinas, sistemas de almacenamiento de datos, CPS, en definitiva, de Fabricas Inteligentes [7]. Las tecnologías digitales aplicadas a la Industria de la Fabricación están cambiando la forma de diseñar, producir, comercializar y generar valor a partir de los productos y de sus servicios asociados [8]. Smart Factory incorpora Cloud, redes industriales, terminales de control de supervisión con elementos inteligentes en el shop-floor.

El Grado en Ingeniería Mecánica **requiere** enfocar el proceso de enseñanza-aprendizaje en el sentido de cubrir las necesidades que, la fabricación flexible basada en Industria 4.0, demanda. Mejorando las posibilidades de un aprendizaje más efectivo e innovador que permita la obtención de las competencias necesarias para la óptima adaptación del Ingeniero Mecánico al mercado laboral. Entendiendo por “competencia” la habilidad para responder a las demandas o llevar a cabo tareas con éxito, en base a dimensiones cognitivas y afectivas [9]. Teniendo una competencia que integra y relaciona las características personales, el contexto y la demanda de perfiles asociados al Ingeniero Mecánico.

El término “*Machine Learning*” fue acuñado por John McCarthy en 1956 y define la capacidad de hacer máquinas inteligentes a nivel humano y multiusos [10]. Es una rama de la inteligencia artificial con el objetivo de que los ordenadores aprendan. Se trata para ello de crear programas capaces de generar patrones de comportamiento a partir de unos datos. Los avances en la comprensión del aprendizaje humano han inspirado metodologías de machine learning (ML), tales como las redes neuronales artificiales, basadas en la estructura de interconexión de redes neuronales en humanos. Algunos ejemplos de aplicaciones son el reconocimiento de voz, la detección de fraude, el procesamiento de imágenes, la clasificación de la secuencia de ADN o las predicciones deportivas, entre otras. ML no sólo hace uso de las

matemáticas, sino también de la capacidad de resolver problemas [11].

ML es la simulación mediante modelado por ordenador del proceso de pensamiento en los humanos. Interactuando mediante lenguaje natural y consiguiendo incrementar sus capacidades. Los sistemas tradicionales analizaban datos estructurados, los sistemas cognitivos son capaces de entender el lenguaje de los humanos y aprender de la información recibida. Procesando gran cantidad de información procedente de múltiples fuentes, adaptándose la máquina al humano. Y esto ayuda en la toma de decisiones, al tener mayor garantía de éxito y estar basadas en el análisis de grandes cantidades de información. Los sistemas cognitivos son probabilísticos y se adaptan a la complejidad de los datos no estructurados, ofreciendo hipótesis con un cierto nivel de acierto. La elaboración de un modelo de predicción, en este sentido, puede inferir una probabilidad de acierto mayor en la toma de decisiones.

Cognitive Computing, por tanto, está muy relacionada con los problemas que pueden resolver los humanos, caracterizados éstos por la incertidumbre y la ambigüedad. Intentando reproducir los procesos psicológicos y biológicos que se producen en el cerebro. El aprendizaje automático relacionado con los sistemas cognitivos acomete el proceso psicológico del aprendizaje, teniendo en cuenta los algoritmos necesarios para aprender a partir de la observación de datos.

Educational Data Mining es la aplicación de minería de datos, aprendizaje automático y estadística, aplicados a la información generada a partir de entornos educativos. Su objetivo es comprender mejor el proceso de aprendizaje y su entorno. El potencial de la minería de datos permite analizar y descubrir la información oculta en ellos, algo difícil de hacer manualmente y que requeriría de mucho tiempo. Una aplicación de ML en educación viene asociada al e-Learning. En este tipo de aprendizaje la presencia del docente ya no viene caracterizada de la misma manera que en el aprendizaje presencial. En este caso la realimentación, en la que se posibilita que el profesor/a monitorice el progreso del estudiante para reajustar ciertos parámetros y hacer el aprendizaje más efectivo, se pierde. La mayoría de los enfoques en e-Learning personalizan el contenido para adaptarlo a diferentes objetivos de aprendizaje. Pero se puede aplicar ML para personalizar también la presentación del contenido [12].

Las redes neuronales artificiales están basadas en las redes neuronales de los humanos. El cerebro humano contiene alrededor de cien mil millones de neuronas perfectamente organizadas y conectadas entre sí. Esas cien mil millones de neuronas forman alrededor de cien billones de conexiones sinápticas. Cada una de esas neuronas recibe alrededor de mil conexiones, generando así un sistema complejo.

Las sinapsis son canales para el flujo y almacenamiento de la información. Santiago Ramón y Cajal describió el principio de la polarización dinámica por el cual una neurona presenta una zona receptora de mensajes (dendritas), una zona integradora de los mismos (soma neuronal), otra zona conductora (axón) y una zona transmisora (terminal sináptica) que se encarga de codificar el mensaje y llevarlo a la siguiente neurona. Por lo tanto, la función fundamental de la neurona consiste en recibir la información, procesarla y enviarla. La comunicación entre las neuronas tiene lugar en unas zonas especializadas de contacto denominadas sinapsis. Por lo que el proceso de comunicación entre neuronas se conoce como transmisión sináptica. El gran avance en el conocimiento de la comunicación neuronal se debe a la electrofisiología y a la incorporación de la biología molecular al estudio de la transmisión sináptica [13].

El objetivo de este trabajo consiste en proponer la incorporación de Machine Learning y de Educational Data Mining como herramientas asociadas al proceso de enseñanza-aprendizaje para el Grado en Ingeniería Mecánica.

METODOLOGÍA

En este trabajo se propone incorporar Machine Learning y Educational Data Mining como herramientas para la mejora del proceso de enseñanza-aprendizaje aplicado al Grado en Ingeniería Mecánica. Para ello, se realiza una revisión bibliográfica y se tiene en cuenta un conjunto de artículos de interés relacionados con el tema.

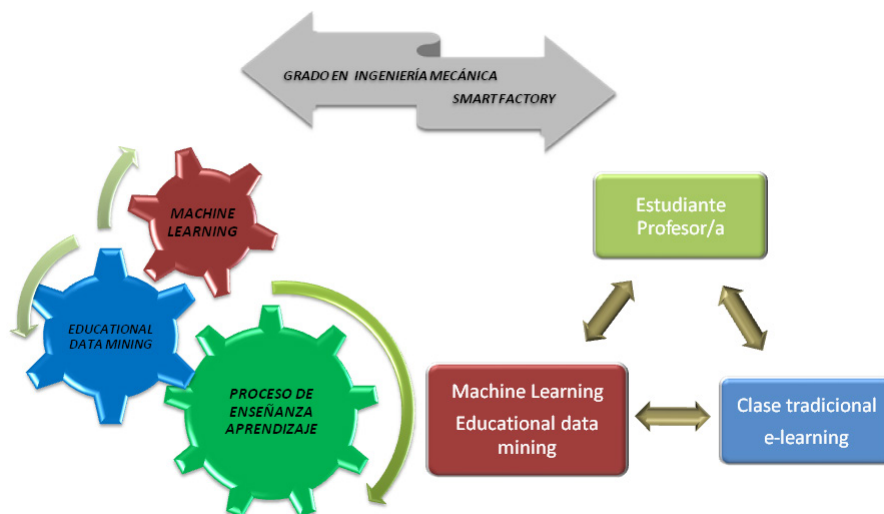


Figura 1. Sistemas Cognitivos asociados al proceso de E/A.

Aprender implica construir y modificar el conocimiento, las habilidades, actitudes, conductas, estrategias y creencias. Que el estudiante de Grado en Ingeniería Mecánica aprenda, por tanto, implica construir y modificar su conocimiento, así como sus habilidades, estrategias, creencias, actitudes y conductas [6].

Para el Grado en Ingeniería Mecánica el estudiante ha de obtener las competencias necesarias que le habiliten para el desempeño adecuado a nivel profesional. Hay diferentes técnicas para evaluar el rendimiento alcanzado por los estudiantes, siendo la minería de datos una de las técnicas aplicadas en el ámbito de la educación [14]. Es lo que se conoce como Educational Data Mining.

La información y los patrones de datos sirven para hacer una estimación del resultado que alcanzan los estudiantes y permite a los profesores/as, en base a esos datos, establecer modificaciones para aumentar el índice de logro mediante la mejora en el proceso de enseñanza-aprendizaje. Mostrando también al estudiante, aquellos aspectos de su aprendizaje en los que ha de incidir más, o abordarlos de manera diferente, si quiere obtener mejores resultados.

Una revisión sistemática sobre el tema en base a artículos publicados entre 2002 y enero de 2015 [15] muestra cuáles son las características más importantes empleadas en la predicción del rendimiento de los estudiantes y los métodos de predicción asociados.

Del resultado de esta revisión se ha deducido que la característica más empleada que definía la predicción del rendimiento del estudiante era considerar el promedio académico acumulativo (cumulative grade point average: CGPA) y la evaluación interna (definida en base a la nota asignada, pruebas, actividades de laboratorio, test de clase y asistencia [16]). Siendo la principal razón para ello, el hecho de considerar CGPA como un indicador de potencial académico realizado [17].

El método predictivo se puede llevar a cabo mediante categorización, regresión o clasificación, siendo el más habitual éste último. Abordando el método predictivo mediante clasificación, se tienen en cuenta el algoritmo del árbol de decisiones [18] y el de las redes neuronales artificiales [19].

Tabla 1. Exactitud de la predicción en función del tipo de algoritmo empleado.

<i>Algoritmo</i>	<i>Característica</i>	<i>Resultados</i>	<i>Autor</i>
Árbol de decisiones	CGPA	91%	Jishan et al. (2005) [21]
Árbol de decisiones	Evaluación interna	76%	Romero et al. (2008) [3]
Redes neuronales artificiales	CGPA	75%	Jishan et al. (2005) [21]
Redes neuronales artificiales	Evaluación interna	81%	Romero et al. (2008) [3]

Además, teniendo en cuenta el caso de estudio analizado para un sistema educativo basado en la web [22], se observa que la equivocación en el proceso de realización de una actividad, por parte del estudiante, es parte del proceso de aprendizaje, sobre todo si los errores no penalizan y se ven como parte de su proceso de aprendizaje.

RESULTADOS Y DISCUSIÓN

A la hora de diseñar el proceso de enseñanza-aprendizaje de una actividad formativa relacionada con Ingeniería de Fabricación bajo enfoque Industria 4.0 para el Grado en Ingeniería Mecánica resulta conveniente su adaptación por un lado a las demandas del perfil profesional requerido en dicho ámbito y por otro lado tener en cuenta la manera en la que se produce el aprendizaje del estudiante. Machine learning y Educational Data Mining ayudan en ese proceso de feedback proactivo que potencia el aprendizaje del estudiante. Por ejemplo, a partir de datos asociados del estudiante y teniendo en cuenta calificaciones de exámenes, se puede predecir el desempeño del estudiante con una buena aproximación [23]. En base a los dos algoritmos que se han tenido en cuenta, se puede decir que, en el algoritmo por árbol de decisiones, la característica que marca la mayor exactitud (91%) en la predicción del rendimiento de los estudiantes es CGPA. Mientras que la exactitud en el algoritmo por redes neuronales artificiales para la característica de evaluación interna es del 81%. El algoritmo por árbol de decisiones ofrece buenos resultados tanto en el conjunto de datos numéricos como los susceptibles de ser categorizados [13], además de resultar fácilmente interpretable la relación entre variables [24].

CONCLUSIONES

Lo aportado aquí forma parte del trabajo que se está llevando a cabo para la detección y adquisición de competencias necesarias que han de adquirir los Graduados en Ingeniería Mecánica en el contexto de Smart Manufacturing.

Machine Learning, relacionado con los sistemas cognitivos, acomete el proceso psicológico del aprendizaje, teniendo en cuenta los algoritmos necesarios para aprender a partir de la observación de datos. Lo que permite un proceso de enseñanza-aprendizaje más específico derivado del empleo y análisis de los datos obtenidos durante dicho proceso. Permitiendo al profesor/a identificar las necesidades del estudiante y a este último enfocar más correctamente su propio aprendizaje. Además, la visualización mediante gráficos e histogramas sobre los resultados obtenidos permite ver tendencias a simple vista, lo cual resulta también muy útil en el manejo de información para la toma de decisiones.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Schunk, D. H. (2012). *Teorías del aprendizaje. Una perspectiva educativa*. México: Pearson.
- [2] Yániz, C. y Villardón, L. (2006). *Planificar desde competencias para promover el aprendizaje*. Cuadernos monográficos del ICE. Bilbao: Universidad de Deusto.
- [3] González, M.C. y Tourón, J. (1992). *Autoconcepto y rendimiento escolar: sus implicaciones en la motivación y en la autoregulación del aprendizaje*. Navarra: Ediciones Universidad de Navarra.
- [4] Boyatzis, R. (2006). An overview of intentional change from a complexity perspective. *Journal of Management Development*, 25(7), pp. 607-623.
- [5] Daura, F. (2011). Exploración de las cualidades psicométricas de la escala de motivación y estrategias de aprendizaje. *Acta psiquiátrica y psicológica de América Latina*, 57(4), pp. 291-298
- [6] Bologna Working Group. (2005). A Framework for Qualifications of the European Higher Education Area. Bologna Working Group Report on Qualifications Frameworks. Copenhagen: Danish Ministry of Science, Technology and Innovation.
- [7] Monostori, L. (2015). Cyber-physical production systems: Roots from manufacturing science and technology. At-Automatisierungstechnik. doi: <https://doi.org/10.1515/auto-2015-0066>
- [8] Jackson, K., et al. (2016). Digital Manufacturing and Flexible Assembly Technologies for Reconfigurable Aerospace Production Systems. In *Procedia CIRP*. doi: <https://doi.org/10.1016/j.procir.2016.07.054>
- [9] DESECO-OCDE. (2002). Definition and selection of competencies: theoretical and conceptual foundations. Strategy paper.
- [10] El Naqa, I. y Murphy, M. J. (2015). What Is Machine Learning? In *Machine Learning in Radiation Oncology*. doi: https://doi.org/10.1007/978-3-319-18305-3_1
- [11] Essinger, S. D. y Rosen, G.L. (2011). *An introduction to machine learning for students in secondary education*. Philadelphia: IEEE.
- [12] Harry, J. (2014). Promoting education: a state of the art machine learning framework for feedback and monitoring e-learning impact. *2014 IEEE Global Humanitarian Technology Conference- South Asia Satellite: IEEE*.

- [13] Jiménez, Y. (2016). *La Programación Neurolingüística y los Hemisferios Cerebrales como herramientas de aprendizaje*. Logroño: Sin índice.
- [14] Romero, C. y Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems Man and Cybernetics Part C*, 40(6), pp. 601–618. doi: <https://doi.org/10.1109/TSMCC.2010.2053532>
- [15] Amirah, M.S., et al. (2015). A review on predicting student's performance using data mining techniques. *The Third Information Systems International Conference*. doi: <https://doi.org/10.1016/j.procs.2015.12.157>
- [16] Christian, T. M. y Ayub, M. (2014). Exploration of classification using nbtrees for predicting students' performance. En *Data and Software Engineering (ICODSE)*, 2014 International Conference on, IEEE, 2014, pp. 1–6.
- [17] Bin Mat, U., Buniyamin, N., Arsad, P. M., y Kassim, R. (2013). An overview of using academic analytics to predict and improve students' achievement: A proposed proactive intelligent intervention. En *Engineering Education (ICEED)*, 2013 IEEE 5th Conference on, IEEE, 2013, pp. 126–130.
- [18] Natek, S., Zwilling, M. (2014). Student data mining solution–knowledge management system related to higher education institutions. *Expert systems with applications*, 41(14), pp. 6400–6407.
- [19] Gray, G., McGuinness, C., y Owende, P. (2014). An application of classification models to predict learner progression in tertiary education. En *Advance Computing Conference (IACC)*, 2014 IEEE International, IEEE, 2014, pp. 549–554.
- [20] Amirah, M.S., et al. (2015). A review on predicting student's performance using data mining techniques. *The Third Information Systems International Conference*. doi: <https://doi.org/10.1016/j.procs.2015.12.157>
- [21] Merceron, A. y Yacef, K. (2005). *Educational data mining: a case study*. Recuperado de: <https://www.researchgate.net/publication/221297164>
- [22] González, M.C., Tourón, J. (1992). *Autoconcepto y rendimiento escolar: sus implicaciones en la motivación y en la autoregulación del aprendizaje*. Navarra: Ediciones Universidad de Navarra.
- [23] Minaei-Bidgoli, B., Kashy, D.A., Kortemeyer, G., y Punch, W.F. (2003). Predicting student performance: an application of data mining methods with the educational web-based system LON-CAPA in *Proceedings of ASEE/IEEE Frontiers in Education Conference*, Boulder, CO: IEEE.

- [24] Wook, M., *et al.* (2009) Predicting student's academic performance using data mining techniques. En *Computer and Electrical Engineering, 2009. ICCEE'09. Second International Conference, 2*, IEEE, 2009, pp. 357–361.