



## XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



# Contribuciones del gemelo digital y la inteligencia artificial en la industria de la automoción

Otxoa-De-La-Torre, I.<sup>a,\*</sup>, Lopez-Guede, J. M.<sup>a</sup>

<sup>a</sup> Departamento de Ingeniería de Sistemas y Automática, Universidad del País Vasco (UPV-EHU), C/ Nieves Cano 12, 01006, Vitoria-Gasteiz, España.

**To cite this article:** Otxoa-De-La-Torre, I., Lopez-Guede, J. M.. 2022. Digital twin and artificial intelligence contributions towards the automotive industry. XVII Simposio CEA de Control Inteligente.

### Resumen

Factores como la electrificación y la pandemia del Covid-19 están ocasionando tiempos difíciles en la industria del automóvil, obligando a las fábricas a ser más eficientes y flexibles que nunca para hacer frente a la incertidumbre resultante. Ante este panorama, conceptos bajo el paraguas de la Industria 4.0 como el del Gemelo Digital (GD) junto a técnicas de Inteligencia Artificial (IA) se muestran como facilitadores para lograr ambos factores. Con el fin de demostrar su potencial, este trabajo presenta la aplicación de dos técnicas de IA destinadas a mejorar el proceso de llenado del circuito de aire acondicionado (A/C) de los vehículos producidos en la fábrica de Mercedes-Benz de Vitoria-Gasteiz, estando ambas enmarcadas dentro de un proyecto orientado al desarrollo de un GD de dicho proceso.

*Palabras clave:* Industria automoción, Industria 4.0, Gemelo digital, Inteligencia artificial, Clustering, Autoencoders.

### Paper Title in English, Bold Style

### Abstract

Factors like electrification and the Covid-19 pandemic are leading to hard times in the automotive industry, making necessary for factories to be more efficient and flexible than ever to cope with the resulting uncertainty. Against this background, concepts under the umbrella of the Industry 4.0 such as the Digital Twin (DT) and Artificial Intelligence (AI) techniques appear as enablers for achieving these two factors. As proof of their potential, this paper presents the application of two AI techniques oriented to the improvement of the air conditioning (A/C) circuit filling process of the vehicles produced in the Mercedes-Benz Vitoria-Gasteiz factory, both being framed within a DT development project of the said process.

*Keywords:* Automotive industry, Industry 4.0, Digital twin, Artificial intelligence, Clustering, Autoencoders.

## 1. Introducción

A lo largo de su historia, la industria del automóvil ha experimentado numerosas transformaciones para adaptarse a las nuevas exigencias del mercado. Pero lejos de ser suficiente, los tiempos actuales vuelven a exigir nuevos y profundos cambios. Según reconocidas consultoras y revistas internacionales (Cubiss, 2021), (Kuhnert and Stürmer, 2021), las pautas que marcarán el vehículo del futuro pasan por la electrificación, las comunicaciones entre vehículos (V2X), la conducción autónoma y la movilidad compartida. Además, el sector se está viendo afectado por acontecimientos como la pandemia del Covid-19, la escasez de microchips y la guerra

de Ucrania. Son por tanto tiempos complicados, que ponen de manifiesto la necesidad de que las fábricas sean cada vez más flexibles y eficientes para poder sobrevivir.

En este contexto, conceptos como el del Gemelo Digital (GD) (Grieves and Vickers, 2017) dentro de la corriente de la Industria 4.0 (Lasi *et al.*, 2014) aparecen como respuesta estratégica a estas necesidades de eficiencia y flexibilidad. Su base tecnológica reside en el Internet de las Cosas (IoT) (Ashton, 2009), que propone la integración de electrónica, software y conectividad en los dispositivos para favorecer la recogida y transferencia de datos a través de la red. La recepción en tiempo real de estos datos permite la construcción de representaciones virtuales de las entidades de las que proceden, dando lugar al concepto de GD. Además, el

procesamiento de estos datos mediante técnicas de Inteligencia Artificial (IA) permite controlar, simular y predecir los posibles estados del gemelo físico representado. Así, la adopción del GD proporciona a las organizaciones la oportunidad de monitorizar y optimizar sus operaciones ganando en eficiencia y flexibilidad, desarrollar productos y servicios innovadores, así como diversificar la creación de valor y los modelos de negocio, entre otros (Lu *et al.*, 2020).

Perteneciendo a este sector y con el fin de manejar toda esta incertidumbre, la fábrica de Mercedes-Benz de Vitoria-Gasteiz se encuentra actualmente desarrollando numerosos proyectos relacionados con la digitalización y la Industria 4.0. Esto incluye la implementación de GDs para varios de sus procesos productivos, siendo el del llenado de los circuitos de aire acondicionado (A/C) uno de ellos. Dentro de este proyecto y como parte de las funcionalidades del GD previstas, se han ideado dos casos de uso que apoyados sobre técnicas de IA prometen ser de gran valor.

El objetivo de este documento es presentar ambos junto con los planes para su desarrollo. Así, la Sección 2 comienza ofreciendo una breve descripción del proceso de llenado de A/C, acompañada de los principales inconvenientes que existen en él. Seguidamente, la Sección 3 presenta los dos casos de uso basados en la IA que pretenden resolver los problemas anteriores, incluyendo los materiales y métodos concretos que se planean utilizar para su desarrollo.

## 2. Proceso de llenado de los circuitos de A/C y problemas asociados

La fábrica de Mercedes-Benz de Vitoria-Gasteiz ha desarrollado su propio proceso de llenado, cuya curva característica se muestra en color azul claro sobre la Figura 1. Básicamente, se compone de una fase de presurización destinada a la detección de fugas desde el interior hacia el exterior, una fase de vacío orientada a la identificación de fugas desde el exterior hacia el interior, una fase de recuperación de vacío en la que recupera el vacío que se hubiera podido perder como consecuencia de un cambio de línea que deben de realizar los vehículos, y finalmente, una fase de carga en la que se procede a llenar el circuito con el gas refrigerante correspondiente siempre y cuando no se hayan detectado fugas en las etapas anteriores.

Actualmente, existen dos problemas principales relacionados con el proceso. El primero de ellos está relacionado con una falta de dominio del mismo, siendo uno de los motivos la captura incompleta de datos que se realiza. En lugar de registrar todos los valores de presión a lo largo de un ciclo, sólo se leen ciertos puntos de presión en instantes prefijados, haciendo que la curva resultante de su unión se aleje de la ya presentada como teórica (ver Figura 1). Por consiguiente, esto impide tener un conocimiento exacto del comportamiento real descrito por los circuitos de los vehículos en el momento del llenado. La otra razón tiene que ver con la explosión en las opciones de configuración de los vehículos motivada por las actuales demandas del mercado (longitud de los vehículos, A/C delantero/trasero, motor de combustión/eléctrico, ...), afectando muchas de ellas a las propiedades de los circuitos de A/C. Esto ha provocado una ruptura de los esquemas y procedimientos tradicionales de la

fábrica para acometer los llenados, ya que todos ellos estaban asentados sobre la poca variabilidad característica de épocas anteriores. En otras palabras, prácticamente la totalidad de los circuitos de A/C eran idénticos, lo que permitía suponer la igualdad entre sus curvas de llenado y la existencia de no más de un par de curvas de referencia. En consecuencia, los ingenieros de proceso se enfrentan a la necesidad de descubrir las posibles nuevas variantes de llenado que existen y reacondicionar el proceso en consonancia.

El segundo problema tiene que ver con la ausencia de estrategias de mantenimiento predictivo para la detección temprana de anomalías en las consolas encargadas de realizar los llenados. Los enfoques actuales de mantenimiento preventivo no sirven para detectar las pequeñas desviaciones que surgen momentáneamente, derivando muchas veces en grandes fallos que afectan negativamente a los objetivos de producción, costes y eficiencias.

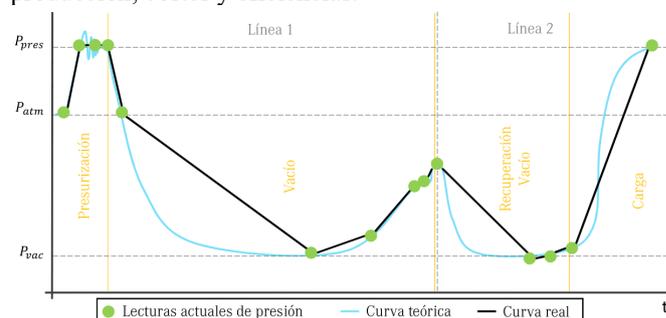


Figura 1: Comparación entre la curva de llenado de A/C teórica y la que es posible obtener en la actualidad.

## 3. Propuestas de resolución: materiales, métodos y resultados esperados

Con el fin de superar los dos problemas descritos, seguidamente se presenta una propuesta de resolución para cada uno de ellos. Ambas se basan en técnicas de IA, empleando datos del proceso como materia prima. En particular, se sugiere el uso de una técnica de clustering para la identificación de las diferentes variantes de llenado que existen dentro de la cartera actual de vehículos. En cuanto a la detección de anomalías, se propone un enfoque consistente en el entrenamiento de redes neuronales de tipo autoencoder. Cabe apuntar que la implementación de cualquiera de ellas requiere de una actualización del sistema de adquisición de datos, de forma que se registre la totalidad de la curva por cada llenado realizado.

### 4.1. Clustering para la identificación de variantes de llenado

El clustering (Milligan and Cooper, 1987) es una conocida técnica de clasificación no supervisada que consiste en dividir una determinada población de datos en diferentes grupos, buscando la mayor unión intragrupal a la vez que la máxima separación intergrupala. Trasladado al escenario de los llenados de los circuitos de A/C, la aplicación de tal técnica sobre los datos de vehículos ya llenados parece ser una herramienta prometedora para ayudar a los ingenieros a detectar patrones, identificar nuevas variantes de llenado y obtener sus correspondientes curvas de referencia. Concretamente, la entrada para el algoritmo debería de ser un conjunto de datos

compuesto por ciclos de llenado OK de vehículos, incluyendo asimismo los códigos comerciales relacionados con el circuito de A/C asociados a cada uno de ellos. Sobre esta base, se espera que el algoritmo de clustering identifique y agrupe todas aquellas variantes de vehículos que, aun siendo diferentes en términos de códigos comerciales, sus circuitos de A/C muestren un comportamiento similar durante el proceso de llenado. Como salida, debería de proporcionar las particiones detectadas que vienen a representar variantes de llenado diferentes, aportando por cada una de ellas la curva de referencia que la caracteriza y el grupo de vehículos procedente del conjunto de datos original que le pertenece. Igualmente, se podrían calcular las agrupaciones de códigos comerciales que definen a cada uno de los clusters descubiertos. La Figura 2 pretende representar todo este proceso. En cuanto al algoritmo de clustering y medida de distancia específicos a utilizar, dado que los datos a manejar vienen a ser series temporales de longitud variable, una estrategia basada en el uso conjunto del popular algoritmo k-means (Hartigan and Wong, 1979) junto con la medida de similitud Dynamic Time Warping (DTW) (Berndt and Clifford, 1994) parece ser razonable.

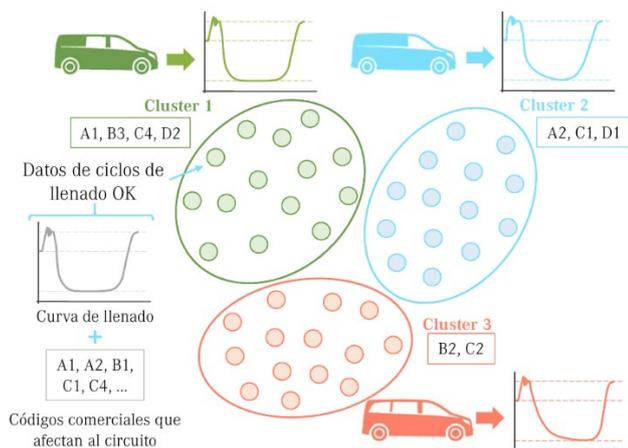


Figura 2: Representación del proceso de aplicación de un algoritmo de clustering sobre los datos del proceso de llenado A/C, ilustrando las posibles entradas y salidas.

#### 4.2. Autoencoders para la detección de anomalías

Un autoencoder es un tipo especial de red neuronal artificial que intenta aprender a generar como salida lo mismo o algo similar a lo que recibe como entrada (ver estructura de red en la Figura 3). Esta propiedad y comportamiento de los autoencoders los hace ideales para escenarios de detección de anomalías (An and Cho, 2015). Llevado al contexto de los llenados de circuitos de A/C, en caso de que un autoencoder se entrene sólo con muestras de ciclos de OK pertenecientes a una variante de llenado específica, es de esperar que la red sea capaz de extraer y aprender las características más relevantes que definen a tales ciclos. De este modo, una vez se complete el entrenamiento de un modelo y llegado el punto de ponerlo en producción, se deberá de prestar especial atención a aquellos ciclos de llenado que vengán categorizados como OK por las consolas que los realizan. Si realmente no presentan ninguna irregularidad, el error de reconstrucción será mínimo

y no será necesario hacer saltar las alarmas. Sin embargo, en caso de contener alguna anomalía, se presupone que el error de reconstrucción será significativo, provocando en este caso el disparo de las alarmas en señal de que algo está fallando en la consola que originalmente los realizó. Más aún si esto ocurre repetidamente por cada ciclo y sobre la misma consola. Ante tal situación, la idea es que las alarmas lleguen al equipo de mantenimiento de modo que puedan realizar las comprobaciones y reparaciones oportunas a tiempo antes de que se produzcan fallos mayores. Todo este escenario queda representado en la Figura 3. En cuanto a los ciclos directamente categorizados como NOK por las consolas de llenado, cabe apuntar que no es necesario hacerlos pasar por los autoencoders entrenados. Evidentemente, éstos harían saltar las alarmas puesto que el error de reconstrucción sería sustancial. Sin embargo, estas situaciones no son motivo de alerta, ya que la categorización NOK del ciclo inicialmente proporcionada por la consola es muestra suficiente de que el error no proviene de la misma sino que del propio circuito del vehículo (posiblemente una o más fugas).

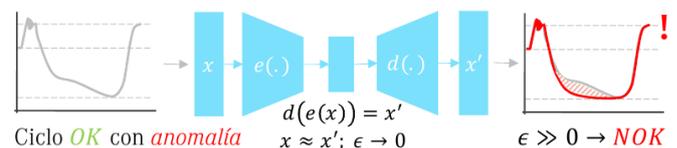


Figura 3: Situación en la que el ciclo recibido viene categorizado como OK aunque sí que contiene una anomalía. Esto se percibe en el error de reconstrucción, haciendo saltar las alarmas.

#### Agradecimientos

Este trabajo ha sido realizado gracias al apoyo de la fábrica de Mercedes-Benz Vitoria a través del programa PIFG19/29.

#### Referencias

- An, J. and Cho, S., 2015. Variational autoencoder based anomaly detection using reconstruction probability. Special Lecture on IE, 2(1), pp.1-18.
- Ashton, K., 2009. That 'internet of things' thing. RFID journal, 22(7), pp.97-114.
- Berndt, D.J. and Clifford, J., 1994. Using dynamic time warping to find patterns in time series. In KDD workshop, Vol. 10, No. 16, pp. 359-370.
- Cubiss, J., 2021. The future of automotive and mobility. Forbes (online).
- Grieves, M. and Vickers, J., 2017. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In Transdisciplinary perspectives on complex systems, pp. 85-113. Springer, Cham.
- Hartigan, J.A. and Wong, M.A., 1979. Algorithm AS 136: A k-means clustering algorithm. Journal of the royal statistical society. series c (applied statistics), 28(1), pp.100-108. 9.
- Kuhnert, F., Stürmer, C., 2021. Five trends transforming the automotive industry. PwC (online).
- Lasi, H., Fettke, P., Kemper, H.G., Feld, T. and Hoffmann, M., 2014. Industry 4.0. Business & information systems engineering, 6(4), pp.239-242.
- Lu, Y., Liu, C., Kevin, I., Wang, K., Huang, H. and Xu, X., 2020. Digital Twin-driven smart manufacturing: Connotation, reference model, applications and research issues. Robotics and Computer-Integrated Manufacturing, 61, p.101837.
- Milligan, G.W. and Cooper, M.C., 1987. Methodology review: Clustering methods. Applied psychological measurement, 11(4), pp.329-354.
- Zhou, C. and Paffenroth, R.C., 2017. Anomaly detection with robust deep autoencoders. In Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 665-674)