

# Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (*deep learning*) al análisis y mejora de la eficiencia de procesos industriales

Ana González Muñiz

Tutor: Ignacio Díaz Blanco

## Resumen

En la última década, las técnicas de aprendizaje profundo o *deep learning* se han convertido en una de las ramas más destacadas de la Inteligencia Artificial, aportando resultados muy superiores a los obtenidos hasta el momento con otras técnicas de aprendizaje automático. A día de hoy, estas técnicas ya han demostrado su éxito en variadas aplicaciones (como el reconocimiento facial y de voz, o el procesamiento natural del lenguaje) e importantes empresas tecnológicas (Google, Facebook, Microsoft, etc.) ya las han incorporado como herramientas de desarrollo de sus productos. Sin embargo, el uso del *deep learning* todavía no se ha implantado en el sector industrial, constituyendo así un interesante campo de estudio aún por explorar.

Es por ello que a lo largo del presente TFM se ha investigado la aplicabilidad de las técnicas de *deep learning* en la industria, tratando de transferir las ideas que ya han demostrado buenos resultados en otros campos al ámbito de los procesos industriales y sistemas de ingeniería. Con este fin, se ha analizado el comportamiento de diferentes arquitecturas *deep learning* (redes *feedforward*, convolucionales, recurrentes y *deep autoencoders*) ante distintos casos de estudio (detección de fallos en un proceso industrial, predicción de comportamiento, extracción de descriptores relevantes del proceso y reducción de la dimensión para analítica visual), utilizando para ello la combinación de librerías *open source* Keras-Tensorflow.

## 1. Detección de fallos en un proceso industrial

Las redes profundas permiten abordar una tarea tan habitual en el ámbito industrial como es la clasificación. En este sentido, se ha propuesto el análisis de datos de corriente y aceleración de un **motor de inducción** (aceleración vertical, aceleración horizontal y corriente en fase R) con el fin de **clasificar el estado de funcionamiento** del mismo (funcionamiento normal, fallo eléctrico, fallo mecánico, etc.).

Para ello, se han planteado dos alternativas: una red *feedforward* y una red convolucional. Ambas arquitecturas han aportado buenos resultados (Tabla 1), destacando especialmente la red convolucional, que es capaz de determinar el estado de funcionamiento del motor analizado con una tasa de aproximadamente el 100% de acierto (Figura 1).

	Entrenamiento	Test
Arquitectura <i>feedforward</i>	86.1%	86.5%
Arquitectura convolucional	99.7%	100.0%

Tabla 1. Tasa de acierto obtenida en la clasificación ante los datos de entrenamiento y test (70-30%).

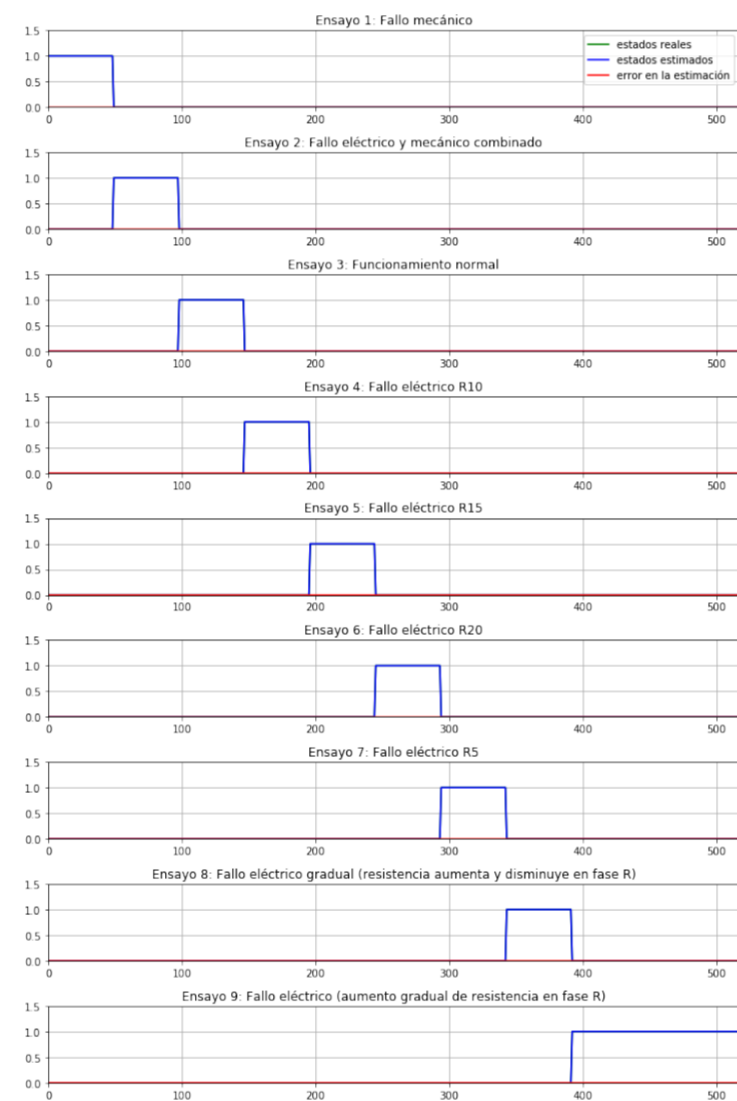


Figura 1. Clasificación de estados de acuerdo a la red convolucional, contemplando nueve ensayos de trabajo diferentes.

## 4. Visualización de datos del proceso

En último lugar, se ha propuesto el estudio de procesos industriales con un enfoque de analítica visual. Para ello, se ha trabajado de nuevo sobre los datos de corriente y aceleración del **motor de inducción**, planteando su análisis a través de una arquitectura de tipo *deep convolutional autoencoder*.

Esta red profunda permite **reducir la dimensión** del espacio de datos de entrada, generando como resultado un mapa de estados 2D en el que cada estado del motor tiene asociada una región diferente del espacio (Figura 5). De esta forma, la arquitectura de red proporciona la posibilidad de monitorizar visualmente el comportamiento del motor de inducción.

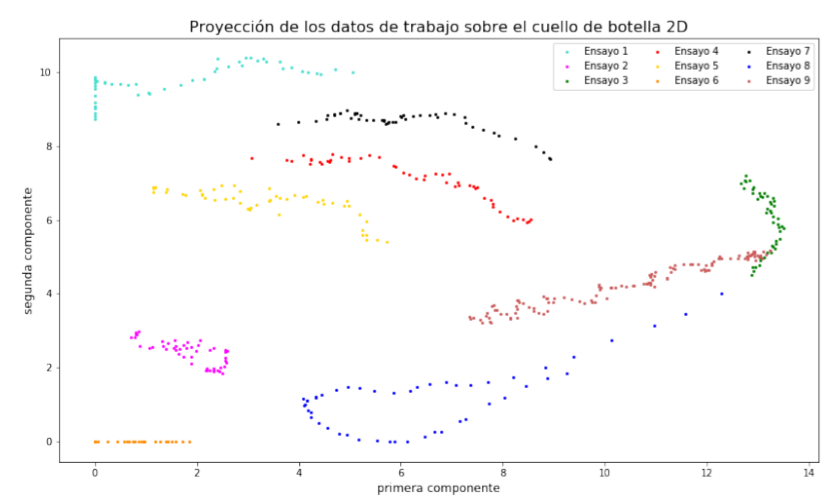


Figura 5. Reducción de la dimensión obtenida con el *deep convolutional autoencoder*.

## Conclusiones

A la vista de los resultados obtenidos, queda **demonstrada la aplicabilidad de las técnicas de *deep learning* en el ámbito industrial**, tratándose de valiosas herramientas con potenciales beneficios en el sector (optimización de los procesos, reducción de costes, mayor productividad y eficiencia).

## 2. Predicción de comportamiento de un sistema de ingeniería

La predicción de comportamiento es otro problema de interés en el ámbito de la ingeniería. Para abordarlo, se ha propuesto la **predicción de consumo energético** a 24 horas vista, en base a los consumos horarios de los últimos dos días y a ciertos valores de contexto (hora del día, día de la semana, semana del año).

De nuevo, se han planteado varias alternativas para resolver este problema: una red *feedforward*, una red convolucional y una red LSTM. Las tres arquitecturas han aportado buenas estimaciones (Tabla 2), aunque el mejor comportamiento ha sido el de la red LSTM (Figura 2), que ha demostrado un gran potencial en el análisis de secuencias temporales.

	Entrenamiento	Test
Arquitectura <i>feedforward</i>	$6.88 \times 10^{-4}$	$9.04 \times 10^{-4}$
Arquitectura convolucional	$5.90 \times 10^{-4}$	$6.00 \times 10^{-4}$
Arquitectura LSTM	$5.55 \times 10^{-4}$	$5.99 \times 10^{-4}$

Tabla 2. Error cuadrático medio de la predicción ante los datos de entrenamiento y test (70-30%).

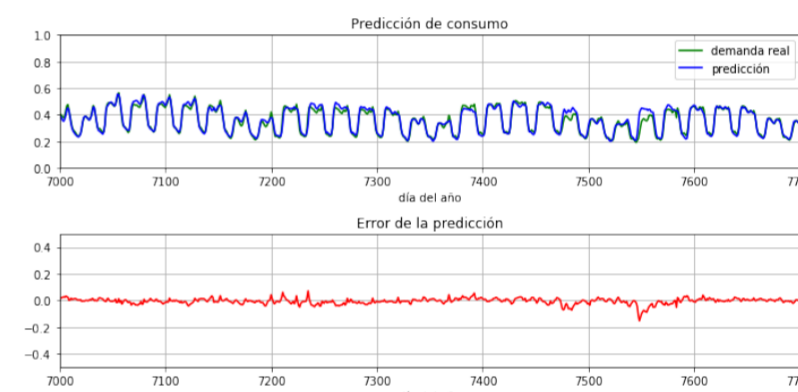


Figura 2. Predicción de consumo con arquitectura LSTM.

## 3. Extracción de características del proceso/sistema analizado

Dado que las redes profundas tienen la particularidad de aprender las fases de extracción de características, se expone en esta sección el **estudio de las características aprendidas por las redes**, en busca de **información desconocida** acerca de los procesos. En concreto, se ha planteado el análisis de las máscaras y filtros aprendidos por las capas de convolución, que contienen gran cantidad de información y son fácilmente interpretables. Para ello se han propuesto dos casos de estudio: el análisis de los filtros utilizados en la clasificación de estados del motor de inducción y el análisis de la máscara empleada para la predicción de consumo energético.

Por un lado, el estudio de los filtros de convolución aprendidos por la red de clasificación, permite extraer parámetros de funcionamiento del motor de inducción, como: la frecuencia de alimentación, la velocidad de giro del motor (RPM), la frecuencia de paso en la pista interior del rodamiento (BPFI) o la frecuencia de paso en la pista exterior del rodamiento (BPFO). Adicionalmente, a partir de estos parámetros de funcionamiento se han inferido parámetros constructivos del motor, como el número de bolas del rodamiento o la relación de proporción entre el diámetro de las bolas y el diámetro del rodamiento.




Figura 3. Filtros aprendidos por la arquitectura convolucional de clasificación.

Por el otro lado, el estudio del vector de pesos aprendido por la red de predicción ha sacado a la luz las horas relevantes para la predicción de consumo, que son aquellas asociadas a los pesos más elevados (en la Figura 4, menor nivel de gris): consumo en la última hora, consumo hace 24 horas y consumo hace 48 horas.




Figura 4. Máscara de convolución aprendida por la red, donde cada peso representa una hora de consumo previo.

## Agradecimientos

Este TFM ha sido desarrollado dentro del grupo de supervisión y diagnóstico de procesos industriales de la Universidad de Oviedo (**GSDPI**: <http://isa.uniovi.es/GSDPI>), sin cuyo apoyo y colaboración esta investigación no habría sido posible.