

# Sistema inteligente para la detección de fallas basado en redes profundas auto-ajustables

Ivo Perez Colo<sup>\*†</sup>, Carolina Saavedra Sueldo<sup>\*†</sup>, Mariano De Paula<sup>\*†</sup>,

Geraldina Roark<sup>†</sup>, Sebastian A. Villar<sup>\*</sup> and Gerardo G. Acosta<sup>\*</sup>

<sup>\*</sup>INTELYMEC, Centro de Investigaciones en Física e Ingeniería del Centro,

UNICEN – CICpBA – CONICET, B7400JWI, Olavarría, Argentina.

<sup>†</sup>Departamento de Ingeniería Industrial, Facultad de Ingeniería,

Universidad Nacional del Centro de la Provincia de Buenos Aires, B7400JWI, Olavarría, Argentina.

Emails: {ivo.perez, carolina.saavedra, mariano.depaula, groark, svillar, ggacosta} @fio.unicen.edu.ar

**Resumen**—La creciente complejidad de los sistemas industriales ha fomentado el surgimiento de nuevas técnicas de análisis de datos para apoyar a los procesos de toma de decisiones. Concretamente, los modelos basados en redes neuronales profundas constituyen una alternativa promisoría para diversas aplicaciones de detección, clasificación y predicción de defectos o fallas que abarca aplicaciones desde el control de calidad de los productos, identificación de defectos en los procesos en una línea de producción hasta predicción de fallas de los equipos tecnológicos. Sin embargo, el éxito de dichos modelos depende sensiblemente de la elección de sus hiper-parámetros para lo cual se requiere de un exhaustivo proceso de configuración que, hoy en día, demanda un alto grado de conocimiento experto. En este contexto, el presente trabajo propone un Sistema Inteligente basado en redes neuronales profundas, dotado con un sistema de auto-ajuste de sus hiper-parámetros, para la detección de defectos y fallas. Dicho sistema integra un algoritmo de Optimización Bayesiana para encontrar la combinación óptima de los hiper-parámetros que permita alcanzar el mejor desempeño posible del sistema. El sistema inteligente propuesto se prueba en dos casos de estudio de diferente naturaleza y los resultados alcanzado demuestran la efectividad de la propuesta.

**Palabras clave**—Redes neuronales profundas, Optimización bayesiana, Detección de defectos visuales, Detección de fallas de máquinas

## I. INTRODUCCIÓN

En el contexto de la Cuarta Revolución Industrial o Industria 4.0, el objetivo de dar forma a sistemas productivos ciber-físicos inteligentes implica la integración de múltiples tecnologías y metodologías a las industrias actuales [1]. La vinculación del sistema físico tradicional con un sistema digital moderno orientado a la incorporación de nuevos componentes tecnológicos como inteligencia artificial, big data, internet de las cosas o computación en la nube, requiere de la materialización de un nuevo paradigma de la información y la comunicación, en el que el flujo de datos e información es continuo [2].

El avance en las distintas tecnologías y componentes de detección, como sensores y cámaras, permite la construcción de sistemas integrados, donde el flujo de información puede aprovecharse para mejorar, o asistir, la toma de decisiones en los procesos de manufactura en busca de aumentar la

capacidad productiva, reducir costos y mejorar la eficiencia del sistema [3]. Las múltiples herramientas y metodologías inteligentes que procesan grandes cantidades de datos, facilitan y automatizan los procesos de decisión dentro de las industrias [4] y fortalecen los sistemas de información, aportando una mayor flexibilidad y mejores resultados en términos de productividad.

Casos como el monitoreo de condiciones de funcionamiento y detección de defectos en la industria implican la consideración de múltiples variables que conforman un nivel complejo de decisión. Por ejemplo, la identificación de defectos en las líneas de producción para llevar a cabo el control de calidad de productos en industrias de manufactura, es un tipo de proceso de toma de decisiones que se ha visto beneficiado con las nuevas tecnologías. Particularmente, la inspección de los productos en distintos puntos de una línea de producción es una tarea que mayoritariamente se ha llevado a cabo mediante visión humana. Sin embargo, este tipo de tareas se ven afectadas por diferentes causas, como por ejemplo la fatiga visual, el cansancio, la subjetividad, entre otros. Otro tipo de proceso de toma de decisiones que puede verse beneficiado por las nuevas tecnologías, es el caso de la interpretación de datos, realizada generalmente en base al conocimiento humano, para la configuración de los planes de mantenimiento de los equipos con vistas a ampliar la vida útil de los mismos aumentando su confiabilidad y consecuentemente su disponibilidad operativa.

Los desarrollos en el campo de la inteligencia artificial han permitido automatizar tareas repetitivas, que en el pasado, debían ser realizadas íntegra y exclusivamente por humanos. Específicamente, las técnicas de visión y aprendizaje artificial han abierto un camino para el desarrollo de metodologías que facilitan y automatizan la detección, diagnóstico y clasificación de defectos y fallas en productos y sistemas industriales. Modelos basados en Redes Neuronales Convolucionales (RNC) demuestran ser satisfactorios en diversas aplicaciones de detección, clasificación y predicción de defectos, especialmente con visión computacional. De igual manera, las aplicación de redes recurrentes LSTM para el

diagnóstico y gestión del estado de salud de los sistemas industriales, han tomado gran impulso en el último tiempo, permitiendo desarrollar planes de control y mantenimiento que aseguren el flujo productivo.

Asimismo, el advenimiento de la personalización masiva de los productos ha resaltado la necesidad de contar con una capacidad de modularización y flexibilidad de los procesos productivos para responder a la dinámica actual de los mercados. En este contexto, las tecnologías de inteligencia artificial generan un relevante aporte para facilitar la adaptación de las industrias a las nuevas tendencias de consumo [5]. A pesar de su relevancia, la necesidad de conocimiento experto para el desarrollo, selección e implementación de soluciones inteligentes integradas a los sistemas productivos, genera dificultades al momento de efectivizar su aplicación en diferentes organizaciones, obstaculizando su transición hacia industrias inteligentes.

De esta forma, surge la necesidad de implementar soluciones flexibles, de libre acceso, que faciliten la integración de técnicas y metodologías inteligentes con los sistemas productivos actuales. Ante este escenario, en el presente trabajo se desarrolla un Sistema Inteligente (SI) auto-ajustable que combina redes neuronales profundas con Optimización Bayesiana (OB), para aplicaciones industriales como es la detección de fallas en producto en proceso y en máquinas eléctricas. La OB permite disminuir el conocimiento experto necesario para el ajuste de las redes y sus hiper-parámetros, reduciendo de esta manera el tiempo final de entrenamiento y el número de pruebas, facilitando su aplicación en diversos ámbitos industriales. Se demuestra el desempeño y confiabilidad del sistema en dos casos de estudio de naturaleza disímil. El primer caso se relaciona con la detección de defectos en una línea de producción de botellas de vidrio mediante inspección visual automática. El segundo caso consiste en el diagnóstico y predicción del estado de salud de máquinas rotativas en función de un conjunto de variables tales como temperatura y vibraciones.

A continuación, se presenta el estado del arte de las metodologías utilizadas, seguido de la propuesta desarrollada, los casos de estudio implementados, los resultados obtenidos y las conclusiones finales del trabajo.

## II. ESTADO DEL ARTE

Muchos procesos de toma de decisiones en los pisos de planta, hoy en día, están siendo asistidos por sistemas artificiales. Como ya se señaló, es común encontrar operaciones de inspección de productos en proceso y terminados en los sistemas industriales que son realizadas por personas. Sin embargo, la visión artificial junto a la inteligencia artificial (IA) basada en Redes Neuronales Artificiales (RNA) son una alternativa para dar soporte a estas tareas, mejorando la eficacia y eficiencia de todo el sistema.

El uso de RNA es un caso ampliamente utilizado dado que, de alguna manera, estos sistemas de procesamiento intentan copiar esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades biológicas

[6]. Por lo tanto, son capaces de aprender de la experiencia y generalizar a partir de señales o datos provenientes del exterior. Particularmente, las Redes Profundas son un tipo de redes neuronales que permiten el procesamiento y modelado de grandes cantidades de datos con relaciones no lineales complejas e incluyen un número elevado de neuronas y capas ocultas [7]. Este tipo de redes ha tenido un acelerado crecimiento en los últimos años, ya que constituyen una tecnología fundamental a la hora de reconocer todo tipo de patrones, exponiendo una gran robustez en diversas aplicaciones de predicción y clasificación [8]–[10].

En la actualidad, estas tecnologías se utilizan en diversos ámbitos y aplicaciones a problemas reales, buscando nuevas soluciones. Por ejemplo, en el trabajo de [11] proponen la utilización de redes neuronales profundas para la detección de defectos en botellas centrándose en la mejora del sistema en base al pre-procesamiento de las imágenes. A pesar de esto, la asignación de hiperparámetros del modelo neuronal y algorítmico para la extracción de características es realizada por defecto sin permitir la variabilidad de los mismos, lo que interfiere con la flexibilidad de aplicación en otros tipos de procesos. De igual modo sucede con la aplicación en botellas de [12], donde comparan la utilización de redes convolucionales con otras metodologías sin especificar los hiperparámetros que utilizan en el caso, siendo estos de vital importancia para la adecuada aplicación de las redes en un sistema inteligente determinado. La topología de red utilizada en [12], se propone inicialmente en [13] para el diagnóstico de fallas en maquinarias rotativas, específicamente en rodamientos. De manera semejante a los casos previos, se hace mención a múltiples experimentos sin especificar la forma de selección de los hiperparámetros que otorgan el desempeño a la red. Lo mismo sucede en [14], [15] y [16], en donde el desempeño del sistema propuesto podría ponerse en discusión al utilizar un proceso de optimización que permita la adaptación de la topología de red y los hiperparámetros utilizados en el algoritmo al caso en estudio.

El empleo de modelos de redes neuronales comprende, inicialmente una etapa de entrenamiento y posteriormente una etapa de testeo del aprendizaje obtenido. En la primera etapa se emplean algoritmos de aprendizaje [17], para encontrar y ajustar los parámetros de los modelos. Sin embargo, cuando se define un modelo neuronal, es necesario definir una serie de hiper-parámetros que determinan, por una parte, la arquitectura de la red neuronal utilizada, por ejemplo, el tamaño del kernel o de la capa oculta; y por otro lado, factores propios de los algoritmos de entrenamiento como son, por ejemplo, el factor de aprendizaje, el tamaño del lote de entrenamiento (batch), que determinarán el comportamiento del algoritmo de aprendizaje durante la fase de entrenamiento. Metodologías como la búsqueda manual, en grilla o aleatoria se han utilizado ampliamente en diversos estudios para la búsqueda de estos hiper-parámetros [18], [19]. Sin embargo, la utilización de metodologías secuenciales han demostrado resultados prometedores respecto a las anteriores.

Sin embargo, cuando aplicamos un algoritmo de entre-

namiento de una red neuronal, lo hacemos sobre un modelo determinado de la misma, es decir, sobre una configuración de su topología fijada de antemano. Encontrar una configuración óptima de la topología de la red, es equivalente a encontrar la combinación de hiper-parámetros que logre el mejor desempeño. Tal es el caso de la OB, la cual ha tenido diversas aplicaciones como en [20]–[22] para encontrar la estructura óptima de una red utilizada. Por ello, la combinación de modelos de optimización para encontrar la mejor arquitectura de una red neuronal es un problema que recientemente está recibiendo atención [23].

### III. ANTECEDENTES METODOLÓGICOS

La evolución y transformación de las tecnologías y herramientas utilizadas en los sistemas interconectados aumentó exponencialmente la cantidad de datos disponibles para el análisis en un corto período de tiempo. Esto es lo que actualmente se conoce como big data. En consecuencia, las metodologías de análisis implementadas para el procesamiento y obtención de información para el proceso de toma de decisiones debieron actualizarse para adecuarse a la complejidad que caracteriza a los extensos conjuntos de datos. De esta forma, las nuevas metodologías basadas en inteligencia artificial combinadas con técnicas de optimización permiten generar sistemas de información inteligentes con mayor robustez y confiabilidad.

#### A. Redes Neuronales Convolucionales

Las RNC surgen como una metodología orientada al procesamiento de grandes cantidades de datos con gran eficiencia, resultando una metodología robusta para la extracción y análisis de información de imágenes, por ejemplo.

Las RNC se consideran redes feed-forward, ya que el procesamiento de la información se realiza en una única dirección, desde la capa de entrada hasta la capa de salida, sin ningún tipo de retroalimentación. Estas redes poseen una estructura característica que imita a las neuronas pertenecientes a la corteza visual del cerebro humano. Están formadas por tres tipos de capas: convolucionales, de reducción de muestreo y totalmente conectadas. En las primeras etapas, las capas convolucionales se encargan de mapear (*feature mapping*) las características principales observadas en los píxeles de la imagen de entrada, con la ayuda de un filtro (conjunto de *kernels*), en múltiples matrices numéricas. Generalmente, las anteriores son seguidas por capas de reducción de muestreo (*pooling*), en las que se reducen las dimensiones espaciales. Esto permite reducir la sobrecarga en el cálculo y el sobre-ajuste del modelo. La salida de estas capas alimenta a capas completamente conectadas destinadas de la clasificación, de tal manera que la última capa entrega la etiqueta de la clase a la que la red determinó que corresponde cada imagen procesada [24].

Este tipo de redes se han aplicado en diversas áreas y procesos industriales. Por ejemplo, en [25] las aplican a la optimización energética y modelado de predicción de industrias petroquímicas, en [26] se utilizan para el diagnóstico

de fallas en rodamientos, en [27] para identificación de tensiones de componentes de acero y en [28] para la homogeneización de materiales heterogéneos. Sin embargo, en estos ejemplos se sigue requiriendo de conocimiento experto para la optimización del aprendizaje, siendo esta optimización mayormente por búsqueda manual.

#### B. Redes LSTM (Long Short Term Memory Networks)

Las redes neuronales LSTM son un tipo de Red Neuronal Recurrente (RNR). Una red de este tipo se distingue de una red neuronal feed-forward en que tiene al menos un circuito de retroalimentación, lo que produce un profundo impacto en la capacidad de aprendizaje de la red y en su rendimiento [17]. Desde el desarrollo de las RNR en los años '80 por los autores Rumelhart, G. E. Hinton y R. J. Williams [29] hasta la actualidad, se han implementado distintas variantes de las mismas. Sin embargo, la mayoría de las RNR propuestas quedaron obsoletas debido a su incapacidad para aprender a largo plazo. Este problema se abordó con el desarrollo de redes que combinan memoria a corto y largo plazo (LSTM) por parte de Hochreiter y Schmidhuber [30].

El proceso de transferencia de datos en las redes LSTM se asemeja al de las RNR estándar, sin embargo la operación de propagación de la información posee ciertas diferencias. Cuando la información pasa a través de la red, ésta decide qué información continuar procesando y cuál dejar ir. La operación principal consiste en células y puertas. El estado celular funciona como una vía para transferir la información. Cuando el estado celular lleva la información, estas puertas ayudan a que la nueva información fluya. Las puertas indicarán qué datos son útiles para guardar y qué datos no lo son; de esta manera solamente los datos relevantes pasan a través de la cadena de secuencias para una fácil predicción.

Las redes recurrentes de tipo LSTM resultan ideales para trabajar con datos secuenciales, donde el tiempo o el orden de los datos juegan un papel preponderante. Hoy en día, se utilizan ampliamente para la traducción de textos, así como también para el reconocimiento de voz y escritura a mano, modelado de lenguaje y etiquetado fonético de marcos acústicos. Otros ejemplos de aplicación de estas redes pueden verse en [31] donde se usan para predecir precios del petróleo crudo, en [32] para estimación de pose y precisión del mecanizado robótico mediante visión, en [33] para predecir con precisión la calidad del agua de la red de drenaje urbano, en [34] aplicadas a un método de cuantificación de incertidumbre de datos de aerogeneradores y en [35] para predecir la trayectoria de un barco.

#### C. Optimización Bayesiana

El éxito en la construcción de estos módulos basados en redes profundas depende de la utilización de diversos hiper-parámetros que determinan el desempeño del aprendizaje y confiabilidad de utilización de la red en los procesos de toma de decisiones dentro de los SI. Sin embargo, la exploración de posibles combinaciones de n-hiper-parámetros que otorguen los resultados esperados resulta compleja. Para esto, el ajuste

de hiper-parámetros (como topología de la red, cantidad de neuronas, tasa de aprendizaje, funciones de activación, entre otros) toma relevancia como una nueva área de investigación, donde propuestas de diversas metodologías y técnicas se han presentado en los últimos años. En este trabajo se propone la Optimización Bayesiana para el ajuste de tales hiper-parámetros.

A diferencia de otras metodologías, la OB se comporta como una estrategia de búsqueda secuencial o Sequential Model-Based Optimization (SMBO) que permite realizar múltiples iteraciones, reduciendo el requerimiento de la experiencia humana y el tiempo que consumen las pruebas [36]. Se trata de una metodología de optimización global que debe satisfacer la ecuación (1) y permite trabajar con funciones del tipo caja negra que resultan complejas de evaluar.

$$x^* = \arg \max_{x \in \chi} f(x) \quad (1)$$

La OB, sintetizada en el Algoritmo 1, inicia con la definición de una función de adquisición  $\alpha(\cdot)$  y un modelo probabilístico que sustituye la función a optimizar representado así la función sustituta  $f$ . Dicho modelo otorga una distribución de probabilidades inicial a la función que se quiere construir, el cual se actualiza luego de cada iteración en base a los datos evaluados. Cada una de las iteraciones realizadas conforman el conjunto de datos  $D = \{x, f(x)\}$ , siendo  $x$  los hiper-parámetros seleccionados del espacio  $\chi$  y  $f(x)$  las correspondientes evaluaciones.

---

#### Algoritmo 1 - Optimización Bayesiana

---

- 1: Definir función de adquisición  $\alpha$
  - 2: Definir modelo estadístico para función sustituta  $f$
  - 3: Iniciar set de datos  $\chi$
  - 4: **Desde**  $n = 1, 2, \dots$  **hacer:**
  - 5:     Obtener  $x_{n+1}$  a partir de la función de adquisición  $\alpha$
  - 6:     Evaluar  $x_{n+1}$  en la función objetivo para obtener  $y_{n+1}$
  - 7:     Actualizar set de datos  $\chi_{n+1} = \{x_n, (x_{n+1}, y_{n+1})\}$
  - 8:     Actualizar modelo estadístico de  $f$
  - 9: **Terminar**
- 

Los hiper-parámetros  $x$  a muestrear en  $f$  son seleccionados a partir de la función de adquisición  $\alpha(\cdot)$ . Esta última, se encarga de verificar a priori la probabilidad de que una muestra candidata merezca ser evaluada en la función objetivo real de forma definitiva, para luego ser incluida en el set de datos del modelo. En definitiva, la función de adquisición tendrá el control sobre el próximo punto a probar con mayor probabilidad de convertirse en máximo global, escogiendo entre la explotación de su conocimiento actual o la exploración de la región definida, a partir del modelo probabilístico de  $f$ , más propensa a contener un nuevo punto de interés.

De esta forma, el espacio de búsqueda de hiper-parámetros se recorre probabilísticamente, sin probar cada una de las combinaciones, sino seleccionando la que mayor posibilidad

posee de otorgar un mejor resultado en base a la regla de Bayes (2).

$$P(f|\chi_n) = \frac{P(\chi_n|f)P(f)}{P(\chi_n)} \quad (2)$$

#### IV. PROPUESTA - SISTEMA INTELIGENTE AUTO-AJUSTABLE

En este trabajo se propone un Sistema Inteligente auto-ajutable que consiste en la integración de redes neuronales profundas con OB para la detección y predicción de fallas en los productos (terminados o en proceso) y equipos, respectivamente; a partir de datos generados en el proceso productivo y capturados en-línea.

Como puede verse en la Fig. 1, el sistema propuesto se desempeña como parte de un nivel de abstracción superior en una planta industrial u organización; donde el nivel inferior consiste en el sistema físico propiamente dicho que se desea analizar u optimizar. Este último, pudiendo estar compuesto por un único elemento o un conjunto de estos; es relevado por medio de sensores, cámaras, escáneres u otros dispositivos que permiten recopilar datos de forma masiva, aportando la información inicial para el entrenamiento y aprendizaje de redes neuronales profundas con OB integrada en el sistema.

El flujo de datos entre el proceso real y el SI puede observarse en la capa intermedia de la Fig. 1.




Fig. 1. Integración del SI al Sistema físico.

El SI propuesto se desarrolló e implementó en lenguaje de programación multiplataforma de código abierto Python, integrando diversas librerías como NumPy, Pandas, Pytorch, Hyperopt, Ray y scikit-learn. Sus componentes se presentan en la Fig. 2, donde existe un primer módulo de aprendizaje con Redes Profundas integrado con un módulo secundario de OB. Ambos módulos interaccionan de forma continua durante la búsqueda del ajuste de hiper-parámetros que otorgue el mejor desempeño aplicado al proceso en análisis.

El primer módulo se compone de dos tipos de redes. Por una lado existe una RNC, estructurada según la Fig. 3 y por el otro, una red de tipo LSTM. Para la primera clase de red se tienen en consideración hiper-parámetros tales como *kernels*, que conforman los filtros de procesamiento, y canales, que permiten extraer diversas características de las imágenes de entrada; mientras que para una red LSTM se optimizan el *lookback* (longitud de la secuencia de datos de entrada a la




Fig. 2. Componentes del SI.

red) y la cantidad de neuronas ocultas. Parámetros como la tasa de aprendizaje, el *batchsize* o el tipo de optimizador, son comunes a las dos situaciones y definen el desempeño del algoritmo. El pseudocódigo presentado en el Algoritmo 2 resume las principales etapas del sistema propuesto.

---

*Algoritmo 2 - Sistema Inteligente Auto-ajustable*

---

- 1: Definir red neuronal a utilizar
  - 2: Definir espacio de hiper-parámetros a evaluar
  - 3: Iniciar **Algoritmo 1 - Optimización Bayesiana**
  - 4: Seleccionar del set de datos  $\chi$  el valor de  $x$  que otorga el mejor desempeño  $y$  de la red
  - 5: Utilizar red entrenada con los datos seleccionados para la toma de decisiones en el proceso productivo en-línea
- 

## V. CASOS DE ESTUDIO

La adaptación del SI desarrollado se demuestra en dos casos de aplicación.

El primer caso se basa en una línea de fabricación de botellas de vidrio, para el que se desea automatizar el sistema de detección de defectos. El dataset de imágenes utilizado en el SI propuesto corresponde al trabajo de [12]. En este artículo, se propone un prototipo de estructura en formato túnel para la captura de imágenes en la línea, con el objetivo de realizar una clasificación binaria entre productos defectuosos y no defectuosos. Para el caso, se utilizan RNC como parte del módulo de redes presentado anteriormente.

El segundo caso de estudio consiste en la aplicación del SI utilizando redes del tipo LSTM para la detección de fallas y el mantenimiento predictivo de maquinaria rotativa. Los conjuntos de datos utilizados corresponden a tres máquinas con distintas propiedades de funcionamiento, las cuales son monitorizadas por una empresa dedicada al seguimiento y mantenimiento de este tipos de equipos.

Los valores corresponden a mediciones de temperatura, velocidad y aceleración, relevando éstos últimos en tres ejes coordenados (x,y,z). La recolección se realiza secuencialmente, cada determinados períodos de tiempo, utilizando los sensores correspondientes. Según el estado de salud determinado en base a los valores relevados, la medición se clasifica teniendo

en cuenta cuatro categorías: óptimo (0), aceptable (1), atención (2) y peligro (3). Para el caso, conceptualizando la Fig. 1, se consideran tres sistemas físicos distintos, correspondientes a cada uno de los motores, debido a las diferencias existentes entre cada uno de ellos.

## VI. PRUEBAS Y RESULTADOS

### A. Detección de defectos visuales en botellas de vidrio

El conjunto de datos utilizado posee un total de 43374 imágenes, las cuales fueron clasificadas entre botellas defectuosas y no defectuosas.

El módulo de OB ajusta los hiper-parámetros del modelo convolucional y del algoritmo de aprendizaje teniendo en cuenta los valores presentados en la Tabla I<sup>1</sup> y la estructura de la red presentada en la Fig. 3.

TABLA I  
HIPER-PARÁMETROS A OPTIMIZAR. CASO DE ESTUDIO A

Hiper-parámetro	Valor inicial	Valor final	Paso
Tamaño de kernel conv1	2	8	1
Canal de salida conv1	8	96	1
Tamaño de kernel pooling	2	15	1
Tamaño de kernel conv2	6	20	1
Canal de entrada conv2	8	96	1
Canal de salida conv2	16	64	1
Batch size	4	32	1
Tasa de aprendizaje	0.001	0.3	Continuo
Momento	0.1	0.99	Continuo
Optimizador	Adam o SGD		

Los rangos elegidos para cada parámetro al igual que la función de distribución gaussiana utilizada en la OB se definieron en base a valores por defecto identificados en las librerías Python antes nombradas, y en la bibliografía de referencia.

Para el conjunto de pruebas realizadas, para cada combinación de hiper-parámetros seleccionada ( $x_n$ ) se utiliza la precisión final de la red como valor a maximizar ( $y_n$ ). Cada entrenamiento se realiza durante 50 épocas, comprobando luego el aprendizaje logrado mediante el testeo. Estos valores evaluados son utilizados por el algoritmo de OB para determinar la próxima combinación  $x_{n+1}$  a probar.

Los resultados finales obtenidos por el SI muestran un nivel de eficacia en la predicción por parte de la red del 97,57%. Los hiper-parámetros que otorgan este desempeño se presentan en la Tabla II. Podemos visualizar la matriz de confusión obtenida en este caso de estudio en la Fig. 4. Estas matrices son herramientas que permiten la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado. La diagonal indica cuántos datos del conjunto de prueba han sido identificados de forma correcta durante la etapa de testeo. Se comprueba que el error en la categorización es del 2,43%, mostrando el adecuado desempeño del sistema.

De esta forma, la RNC optimizada con OB podría emplearse en la línea para la detección de defectos de las botellas

<sup>1</sup>El hiper-parámetro Momento solo aplica cuando el optimizador utilizado es SGD.




Fig. 3. Estructura de la Red Neuronal Convolutiva propuesta.

de vidrio en tiempo real con una gran precisión. Incorporar este tipo de herramienta permite a la industria reducir los desperdicios y retrabajos, impactando directamente en mejores niveles de productividad.

TABLA II  
HIPER-PARÁMETROS SELECCIONADOS CON OPTIMIZACIÓN BAYESIANA.  
CASO DE ESTUDIO A

Hiper-parámetro	Valor	Hiper-parámetro	Valor
Tamaño de kernel conv1	5	Canal de salida conv2	32
Canal de salida conv1	32	Batch size	16
Tamaño de kernel pooling	2	Tasa de aprendizaje	0.001
Tamaño de kernel conv2	5	Momento	-
Canal de entrada conv2	32	Optimizador	Adam

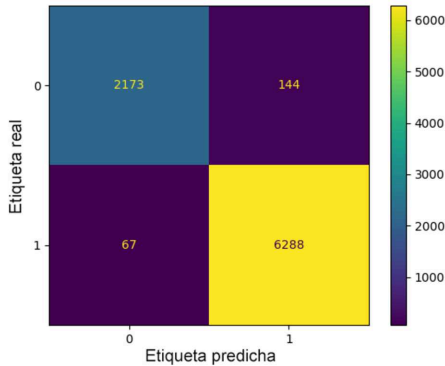


Fig. 4. Matriz de confusión. Caso de estudio A.

### B. Detección de fallas de máquinas para mantenimiento preventivo

En este caso, el SI propuesto se utilizará para predecir el estado de salud de los equipos principales involucrados en un proceso productivo, específicamente en motores eléctricos que son parte neurálgica de diferentes equipos involucrados en un sistema industrial. Particularmente, la empresa con la que se ha trabajado proporcionó datos en archivos formato *.csv*, correspondientes a mediciones de temperatura, velocidad y aceleración de dichas máquinas cada determinados períodos

de tiempo. Cada archivo corresponde a un equipo específico (B1, B2 y B3). La cantidad de datos en cada archivo depende del número de sensores considerados en cada uno de ellos y del correcto funcionamiento de los mismos. Se pueden identificar equipos con 2, 3 o 4 sensores que se encargan de medir las variables antes descritas generando una clasificación final de salud del equipo.

Los datos disponibles resultan suficientes para demostrar la utilización del SI. Sin embargo, para la integración final al proceso real se recomienda aumentar el conjunto de datos de forma tal que el modelo incorpore nueva información y evolucione en el tiempo; permitiendo balancear las distintas categorías y generando una representación de mayor robustez del funcionamiento de los equipos analizados. El desequilibrio de cantidad de datos entre categorías podría generar aprendizajes parciales de la red. Como se resaltó anteriormente, los datos fueron provistos por una empresa especializada en el área, por lo que se mantiene su privacidad.

Del total de datos disponibles, se seleccionó para cada equipo un 80% para la etapa de entrenamiento de la red. La entrada de datos a la red se definió como un vector  $X$ . La longitud del mismo depende del número de sensores  $i$ . Para cada sensor, como ya se mencionó, existen datos de temperatura  $t$ , aceleración  $a$  y velocidad  $v$  en tres direcciones  $(x, y, z)$ . La salida  $Y$  se definió en base al estado de salud: 0, 1, 2 o 3.

$$X = (t_i, x_{ia}, x_{iv}, y_{ia}, y_{iv}, z_{ia}, z_{iv}) \quad (3)$$

En la Tabla III pueden encontrarse los hiper-parámetros a optimizar por medio de la OB utilizando un algoritmo TPE (Tree Parzen Estimator) [37], teniendo en cuenta que la red neuronal es de tipo LSTM. Los valores de los hiper-parámetros (tal como en el caso A) fueron definidos entre límites usuales vistos en la bibliografía sin restricciones de variabilidad.

Luego del entrenamiento con los hiper-parámetros óptimos resultantes de la OB basada en la estructura de árbol, los cuales se presentan en la Tabla IV, y del testeo correspondiente, se comprueba que el SI propuesto alcanza una precisión superior al 94% en todos los casos, llegando al 98% para B3. Se

TABLA III  
HIPER-PARÁMETROS A OPTIMIZAR. CASO DE ESTUDIO B

Hiper-parámetro	Valor Inicial	Valor Final	Paso
Tasa de aprendizaje	0.001	0.3	Continuo
Batch size	4	32	4
Lookback	4	50	2
Neuronas capa oculta	8	32	4
Optimizador	Adam o SGD		

muestran las matrices de confusión en las Fig. 5, 6 y 7, logradas en el testeo final aleatorio con un 20% de los datos.

TABLA IV  
HIPER-PARÁMETROS SELECCIONADOS CON OPTIMIZACIÓN BAYESIANA PARA CADA EQUIPO. CASO DE ESTUDIO B

Hiper-parámetro	B1	B2	B3
Tasa de aprendizaje	0.0795	0.0967	0.0018
Batch size	28	12	28
Lookback	46	50	38
Neuronas capa oculta	24	32	20
Optimizador	SGD	SGD	Adam

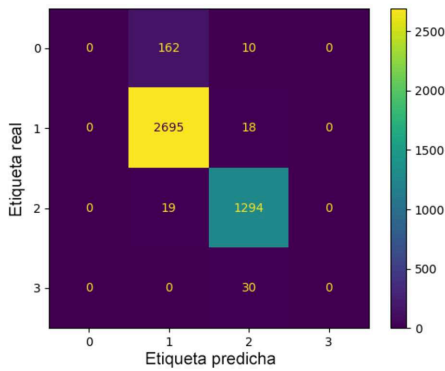


Fig. 5. Matriz de confusión. Caso de estudio B1.




Fig. 6. Matriz de confusión. Caso de estudio B2.

## VII. CONCLUSIONES

En este trabajo se desarrolló un Sistema Inteligente basado en redes neuronales profundas dotado de un sistema de auto-

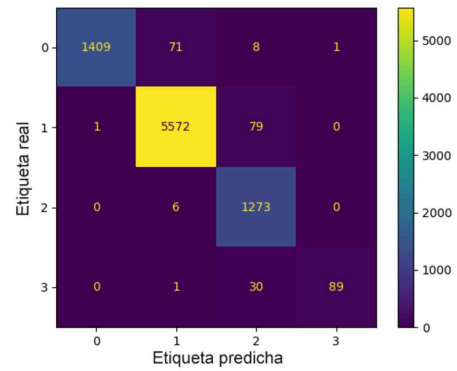


Fig. 7. Matriz de confusión. Caso de estudio B3.

ajuste de sus hiper-parámetros. Su aplicación y funcionamiento se comprobó en dos casos de estudio de detección de defectos y fallas.

Del análisis de resultados alcanzados se concluye que el sistema propuesto facilita la aplicación de redes neuronales en organizaciones productivas, permitiendo enfrentar procesos complejos de toma de decisiones mediante la digitalización y el procesamiento de grandes cantidades de datos. Es relevante destacar que el uso de OB en el sistema reduce notablemente la necesidad de conocimiento experto, disminuyendo considerablemente los tiempos y costos involucrados en el manejo de las redes neuronales artificiales como en el dominio del problema a tratar. De esta forma se facilita la transformación digital de organizaciones productivas hacia industrias inteligentes, con las ventajas competitivas que esto conlleva en el contexto actual.

Como trabajo futuro, se propone ampliar el conjunto de datos disponible y realizar un estudio estadístico extendido, para estimar el intervalo de confianza de la proporción de aciertos respecto a la detección de fallos o defectos de la red, como base para la validación del sistema propuesto. Sumado a esto, se esperan implementar nuevas pruebas que incluyan mayor cantidad de parámetros e hiper-parámetros a optimizar o mayor amplitud del rango en cada uno de ellos. Esto permitirá seguir evaluando el SI desarrollado, explorando nuevas soluciones.

Cabe destacar, además, que la flexibilidad que caracteriza al SI mediante el auto-ajuste, permitirá extender su aplicación a otros problemas complejos de toma de decisiones en organizaciones productivas, generando aportes al control y la optimización de sus procesos, la reducción del error humano y al aumento de productividad y calidad en la producción.

## REFERENCIAS

- [1] J. Namjoshi and M. Rawat, "Role of smart manufacturing in industry 4.0.", *Materials Today: Proceedings*, vol. 63, pp. 475-478, 2022. [Online]. Available: <https://doi.org/10.1016/j.matpr.2022.03.620>
- [2] Y. Lu, C. Liu, K. I-Kai Wang, H. Huang and X. Xu, "Digital Twin-driven smart manufacturing: Connotation, reference model, applications and research issues", *Robotics and Computer-Integrated Manufacturing*, vol. 61, 101837, 2020. [Online]. Available: <https://doi.org/10.1016/j.rcim.2019.101837>

- [3] M. Liu, S. Fang, H. Dong and C. Xu, "Review of digital twin about concepts, technologies, and industrial applications", *Journal of Manufacturing Systems*, vol. 58, part B, pp. 346-361, 2021. [Online]. Available: <https://doi.org/10.1016/j.jmsy.2020.06.017>
- [4] T. Zheng, M. Ardolino, A. Bacchetti and M. Perona, "The applications of Industry 4.0 technologies in manufacturing context: a systematic literature review", *International Journal of Production Research*, vol. 59, issue 6, pp. 1922-1954, 2021. [Online]. Available: <https://doi.org/10.1080/00207543.2020.1824085>
- [5] D. Schneider, T. Fröhlich, T. Huth and T. Vietor, "Design for Flexibility – Evaluation Interactions between Product Properties and Production Processes", *Procedia CIRP*, vol. 91, pp. 814-818, 2020. [Online]. Available: <https://doi.org/10.1016/j.procir.2020.02.240>
- [6] B. M. del Brío and A. Sanz Molina, *Redes neuronales y sistemas borrosos*, 3rd ed. Alfaomega Grupo Editor S.A., 2006.
- [7] V. Mnih et al, "Human-level control through deep reinforcement learning", *Nature*, vol. 518, 7540, pp.529-533, 2015. [Online]. Available: <http://dx.doi.org/10.1038/nature14236>
- [8] Y. Honghui, Z. Kaifeng and L. Junhao, "Open set recognition of underwater acoustic targets based on GRU-CAE collaborative deep learning network", *Applied Acoustics*, vol. 193, 108774, 2022. [Online]. Available: <https://doi.org/10.1016/j.apacoust.2022.108774>
- [9] W. Caicedo-Torres and J. Gutierrez, "ISeeU2: Visually interpretable mortality prediction inside the ICU using deep learning and free-text medical notes", *Expert Systems with Applications*, vol. 202, 117190, 2022. [Online]. Available: <https://doi.org/10.1016/j.eswa.2022.117190>
- [10] L. Guanjun, T. Zhengyang, Q. Hui, L. Shuai, S. Qin, Q. Yuhua and Z. Jianzhong, "Short-term runoff prediction using deep learning multi-dimensional ensemble method", *Journal of Hydrology*, vol. 609, 127762, 2022.[Online]. Available: <https://doi.org/10.1016/j.jhydrol.2022.127762>
- [11] W. Jinjiang, F. Peilun and R. X. Gao, "Machine vision intelligence for product defect inspection based on deep learning and Hough transform", *Journal of Manufacturing Systems*, vol. 51, pp. 52-60, 2019. [Online]. Available: <https://doi.org/10.1016/j.jmsy.2019.03.002>
- [12] M. Le, W. Xiaoyue and L. Zhiwei, "High Precision Medicine Bottles Vision Online Inspection System and Classification Based on Multi-Features and Ensemble Learning via Independence Test", arXiv, 2021. [Online]. Available: <https://arxiv.org/abs/2101.01362>
- [13] Z. Kaiyu, C. Jinglong, Z. Tianci and Z. Zitong, "A Compact Convolutional Neural Network Augmented with Multiscale Feature Extraction of Acquired Monitoring Data for Mechanical Intelligent Fault Diagnosis", *Journal of Manufacturing Systems*, vol. 55, pp. 273-284, 2020. [Online]. Available: <https://doi.org/10.1016/j.jmsy.2020.04.016>
- [14] C. Yuanhong, C. Jinglong, C. Qiang, L. Shen and Z. Zitong, "CFs-focused intelligent diagnosis scheme via alternative kernels networks with soft squeeze-and-excitation attention for fast-precise fault detection under slow & sharp speed variations", *Knowledge-Based Systems*, vol. 239, 108026, 2022. [Online]. Available: <https://doi.org/10.1016/j.knosys.2021.108026>
- [15] L. Haixin, C. Jinglong, Z. Tianci, H. Rujie, P. Tongyang and Z. Zitong, "SDA: Regularization with Cut-Flip and Mix-Normal for machinery fault diagnosis under small dataset", *ISA Transactions*, vol. 111, pp. 337-349, 2021. [Online]. Available: <https://doi.org/10.1016/j.isatra.2020.11.005>
- [16] Z. Ansi, L. Shaobo, C. Yuxin, Y. Wanli, D. Rongzhi and H. Jianjun, "Limited Data Rolling Bearing Fault Diagnosis With Few-Shot Learning", *IEEE Access*, vol. 7, pp. 110895-110904, 2019. [Online]. Available: <https://ieeexplore.ieee.org/document/8793060>
- [17] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Pearson Prentice Hall, 2009.
- [18] Z. Qu, J. Xu, Z. Wang, R. Chi and H. Liu, "Prediction of electricity generation from a combined cycle power plant based on a stacking ensemble and its hyperparameter optimization with a grid-search method", *Energy*, vol. 227, 120309, 2021. [Online]. Available: <https://doi.org/10.1016/j.energy.2021.120309>
- [19] Y. N. Kunang, S. Nurmaini, D. Stiawan and B. Y. Suprpto, "Attack classification of an intrusion detection system using deep learning and hyperparameter optimization", *Journal of Information Security and Applications*, vol. 58, 102804, 2021. [Online]. Available: <https://doi.org/10.1016/j.jisa.2021.102804>
- [20] A. Camero, H. Wang, E. Alba and T. Bäck, "Bayesian neural architecture search using a training-free performance metric", *Applied Soft Computing*, vol. 106, 107356, 2021. [Online]. Available: <https://doi.org/10.1016/j.asoc.2021.107356>
- [21] Z. Ding, W. Zhang and D. Zhu, "Neural-network based wind pressure prediction for low-rise buildings with genetic algorithm and Bayesian optimization", *Engineering Structures*, vol. 260, 114203, 2022. [Online]. Available: <https://doi.org/10.1016/j.engstruct.2022.114203>
- [22] V. Fernandes, G. Braz Junior, A. Cardoso de Paiva, A. Correa Silva and M. Gattass, "Bayesian convolutional neural network estimation for pediatric pneumonia detection and diagnosis", *Computer Methods and Programs in Biomedicine*, vol. 208, 106259, 2021. [Online]. Available: <https://doi.org/10.1016/j.cmpb.2021.106259>
- [23] D. Baymurzina, E. Golikov and M. Burtsev, "A review of neural architecture search", *Neurocomputing*, vol. 474, pp. 82-93, 2022. [Online]. Available: <https://doi.org/10.1016/j.neucom.2021.12.014>
- [24] M. Valizadeh and S. J. Wolff, "Convolutional Neural Network applications in additive manufacturing: A review", *Advances in Industrial and Manufacturing Engineering*, vol. 4, 100072, 2022. [Online]. Available: <https://doi.org/10.1016/j.aime.2022.100072>
- [25] G. Zhiqiang, Z. Yanhui, L. Chengfei, H. Yongming, C. Yunfei and Y. Bin, "Energy optimization and prediction modeling of petrochemical industries, An improved convolutional neural network based on cross-feature", *Energy*, vol. 194, 116851, 2020. [Online]. Available: <https://doi.org/10.1016/j.energy.2019.116851>
- [26] S. Yongjian and L. Shaohui, "Bearing fault diagnosis based on optimal convolution neural network", *Measurement*, vol.190, 110702, 2022. [Online]. Available: <https://doi.org/10.1016/j.measurement.2022.110702>
- [27] L. Deng, S. Xu, W. Wang, and C. Xiang, "Uniaxial stress identification of steel components based on one dimensional-CNN and ultrasonic method", *Measurement*, vol. 194, 110868, 2022. [Online]. Available: <https://doi.org/10.1016/j.measurement.2022.110868>
- [28] R. Chengping and L. Yang, "Three-dimensional convolutional neural network (3D-CNN) for heterogeneous material homogenization", *Computational Materials Science*, vol. 184, 109850, 2020. [Online]. Available: <https://doi.org/10.1016/j.commatsci.2020.109850>
- [29] D. E. Rumelhart, G. E. Hinton and R. J. Williams, "Learning representations by back-propagating errors", *Nature*, vol.323, pp.533-536, 1986. [Online]. Available: <https://doi.org/10.1038/323533a0>
- [30] S. Hochreiter and J. Schmidhuber, "Long short-term memory", *Neural Comput.*; vol. 9(8), pp.1735-80, 1997. doi: 10.1162/neco.1997.9.8.1735
- [31] G. A. Busari and D. H. Lim, "Crude oil price prediction: A comparison between AdaBoost-LSTM and AdaBoost-GRU for improving forecasting performance", *Computers & Chemical Engineering*, vol. 155, 107513, 2021. [Online]. Available: <https://doi.org/10.1016/j.compchemeng.2021.107513>
- [32] D. K. Bilal, M. Unel, L. T. Tunc and B. Gonul, "Development of a vision based pose estimation system for robotic machining and improving its accuracy using LSTM neural networks and sparse regression", *Robotics and Computer-Integrated Manufacturing*, vol. 74, 102262, 2022. [Online]. Available: <https://doi.org/10.1016/j.rcim.2021.102262>
- [33] Z. Yituo, L. Chaolin, J. Yiqi, S. Lu, Z. Ruobin, Y. Kefen and W. Wenhui, "Accurate prediction of water quality in urban drainage network with integrated EMD-LSTM model", *Journal of Cleaner Production*, vol. 354, 131724, 2022. [Online]. Available: <https://doi.org/10.1016/j.jclepro.2022.131724>
- [34] L. Lin, M. Li, L. Ma, A. Bazar and Z. M. Ali, "Hybrid RNN-LSTM deep learning model applied to a fuzzy based wind turbine data uncertainty quantization method", *Ad Hoc Networks*, vol. 123, 102658, 2021. [Online]. Available: <https://doi.org/10.1016/j.adhoc.2021.102658>
- [35] G. Da-wei, Z. Yong-sheng, Z. Jin-fen, H. Yan-kang, Y. Ke and Y. Boran, "A novel MP-LSTM method for ship trajectory prediction based on AIS data", *Ocean Engineering*, vol. 228, 108956, 2021. [Online]. Available: <https://doi.org/10.1016/j.oceaneng.2021.108956>
- [36] F. Hutter, H. H. Hoos and K. Leyton-Brown, "Sequential Model-Based Optimization for General Algorithm Configuration", *Learning and Intelligent Optimization: Proceedings of the International Conference on Learning and Intelligent Optimization*, Berlin, Heidelberg, pp. 507-523, 2011. [Online]. Available: [https://doi.org/10.1007/978-3-642-25566-3\\_40](https://doi.org/10.1007/978-3-642-25566-3_40)
- [37] J. Bergstra, R. Bardenet, Y. Bengio and K. Balázs, "Algorithms for Hyper-Parameter Optimization", *Advances in Neural Information Processing Systems*, vol. 24, 2011. [Online]. Available: <https://proceedings.neurips.cc/paper/2011/file/86e8f7ab32cfd12577bc2619bc635690-Paper.pdf>