



UNIVERSITAT
JAUME·I

TRABAJO DE FIN DE MÁSTER

MÁSTER UNIVERSITARIO EN SISTEMAS INTELIGENTES

**Gemelo Digital en Parques Solares: enfoque
mediante series temporales y aprendizaje
profundo**

Autor: Kamel Arafet Cruz

Tutor: Dr. Rafael Berlanga Llavori

Fecha de lectura: noviembre de 2020

CURSO 2019-2020

RESUMEN

Cada día aumenta la presencia de la generación mediante fuentes renovables de energía, siendo la energía solar una de las de mayor crecimiento. El surgimiento de tecnologías como los Gemelos Digitales dentro del marco de la Internet de las Cosas y la Industria 4.0, permiten un desarrollo sustancial en los sistemas de diagnóstico. El objetivo de este trabajo es la obtención del Gemelo Digital de un Parque Solar Fotovoltaico, mediante la utilización de aprendizaje profundo. Se realiza un procesamiento de las series temporales, reduciendo su dimensionalidad, y seleccionando las métricas más relevantes para el estudio. A continuación, se lleva a cabo un análisis tanto en el dominio temporal como en la frecuencia. Posteriormente se propone un modelo basado en autoencoders con el fin de obtener el Gemelo Digital del sistema a estudiar, logrando un error de reconstrucción sobre 0.1. Este Gemelo Digital es utilizado para la detección de anomalías en el sistema alcanzando un recall de 0.92 y un AUC de 0.97. Por lo tanto, podemos decir que la utilización de técnicas de aprendizaje profundo para la obtención de gemelos digitales obtiene buenos resultados y una respuesta robusta del modelo obtenido.

Palabras claves:

Series Temporales, Parques Solares Fotovoltaicos, Internet de las Cosas, Industria 4.0, Autoencoders, Gemelos Digitales.

ABSTRACT

Every day the presence of generation through renewable energy sources increases, with solar energy being one of the fastest growing. The emergence of technologies such as Digital Twins within the framework of the Internet of Things and Industry 4.0, allow a substantial development in diagnostic systems. The objective of this work is to obtain the Digital Twin of a Photovoltaic Solar Park, with a deep learning approach. The time series are processed, reducing their dimensionality, and selecting the most relevant metrics for the study. Next, an analysis is carried out on both the time domain and the frequency. Subsequently, a model based on autoencoders is proposed in order to obtain the Digital Twin of the system to be studied, achieving a reconstruction error of about 0.1. This Digital Twin is used for the detection of anomalies in the system reaching a recall of 0.92 and an AUC of 0.97. Therefore, we can say that the use of deep learning techniques to obtain digital twins obtains good results and a robust response from the model obtained.

Keywords:

Time Series, Autoencoders, Digital Twins, Photovoltaic Solar Farm, Internet of Things, Industry 4.0.

Índice

RESUMEN.....	3
ABSTRACT.....	4
1. INTRODUCCIÓN	1
2. MARCO TEÓRICO	4
2.1. Series Temporales	4
2.1.1 Análisis en el dominio del tiempo.....	5
2.1.2 Análisis en el dominio de la frecuencia	7
2.2. Aprendizaje Profundo	8
2.2.1 Redes Convolucionales y Recurrentes	9
2.2.2 Autoencoders.....	12
2.3 Gemelo Digital.....	13
2.4 Escenario de aplicación: Parques solares fotovoltaicos	15
2.5 Tecnologías utilizadas.....	17
3. METODOLOGÍA.....	19
3.1 Pre-procesamiento y Análisis de Métricas	20
3.2 Análisis en el Dominio Temporal.....	21
3.3 Análisis en el Dominio de la Frecuencia	23
3.4 Obtención del Gemelo Digital.....	24
3.5 Detección de anomalías	27
4. RESULTADOS	28
4.1 Configuración de los experimentos	28
4.2 Obtención del Gemelo Digital.....	29
4.2.1 Experimentos con pre-procesamiento	29
4.2.2 Experimentos en Dominio del tiempo.....	31
4.2.3 Experimentos en Dominio de la frecuencia	32
4.2.4 Experimentos en Dominio tiempo y frecuencia	34

4.3	Detección de anomalías	35
5.	CONCLUSIONES Y TRABAJO FUTURO.....	39
	Referencias.....	41

1. INTRODUCCIÓN

La disminución de los costes de producción de las energías renovables, así como la influencia de programas como la Agenda 2030 han logrado un aumento de la generación eléctrica basada en estas fuentes. Una de las de mayor crecimiento es la energía solar, solamente en 2019 creció un 22 %, lo cual representa un incremento de 131 TWh respecto al 2018 [1].

La generación eléctrica mediante energía solar se realiza principalmente a través de los Parques Solares Fotovoltaicos (PSFV). Estos están sujetos a las condiciones climáticas, por lo que su ventana de generación es corta. En aras de lograr una mayor eficiencia y disminuir el tiempo de afectación por posibles averías; se hace necesario desarrollar sistemas que, mediante la integración de las nuevas tecnologías con los sistemas existentes, permitan el desarrollo de sistemas más robustos y con capacidad predictiva.

Una parte fundamental en el PSFV, y una de las más propensas a presentar averías, es el Inversor. Este es el equipo encargado de transformar la energía obtenida a través de los paneles solares, de corriente continua en corriente alterna disponible para su transmisión y distribución.

En la actualidad, gracias a avances tecnológicos como la Industria 4.0, la Internet de las Cosas (IoT) y el desarrollo y popularización de técnicas en este marco como los Gemelos Digitales (DT), han permitido lograr un aumento tanto en la eficiencia, seguridad y sostenibilidad de la industria.

El Gemelo Digital no es más que una representación digital de un objeto o sistema físico. Una de sus potencialidades es el análisis continuo del comportamiento de un sistema, no solamente para realizar pruebas de funcionamiento que serían costosas de realizar en el sistema físico, sino también poder detectar e incluso predecir posibles comportamientos anómalos.

Para obtener el DT de cualquier sistema se utilizan los siguientes enfoques:

- Mediante el modelado físico, el cual requiere un conocimiento de experto del sistema.
- Mediante el modelado a través de datos, más utilizado, debido principalmente al alto volumen de datos que hoy se genera en cualquier sistema y la posibilidad de aplicación de técnicas de Inteligencia Artificial.

El primer enfoque, además del conocimiento de nivel experto, puede estar sujeto al nivel de información proporcionada por el fabricante de los dispositivos modelados. En cambio, la obtención del DT mediante datos, plantea un sistema de caja negra, donde solo mediante el acceso a los datos de entradas y salidas, y utilizando técnicas de modelación se obtiene un modelo digital que representa al modelo físico de forma fiable. Este modelo digital tiene como principal limitación que no pueden simularse fácilmente parámetros internos asociados al sistema físico.

El presente trabajo se enmarca en la obtención del DT de un inversor mediante el modelado por datos. Para esto se realiza un análisis exhaustivo de los datos obtenidos de un inversor, perteneciente a un PSFV ubicado en la región oriental de Cuba.

En el marco de estas tecnologías, el mayor volumen de información que se obtiene es a través de Series Temporales, las cuales representan un conjunto de observaciones ordenadas en el paso del tiempo de los diferentes sensores, a través de tecnologías como la IoT, y son cruciales tanto para detectar patrones de comportamiento y anomalías, como obtener de un sistema físico su DT.

Los métodos tradicionales de detección de anomalías se basan en dos enfoques, mediante técnicas estadísticas (ejemplo, ARIMA [2]) o de aprendizaje automático (ejemplo, K-means, SVM, entre otros). Estos métodos obtienen buenos resultados en sistemas supervisados y univariados, pero no logran captar de forma adecuada las relaciones temporales que se establecen en sistemas multi-variables.

En cambio, los algoritmos de aprendizaje profundo, logran captar mejor las dependencias temporales existentes, presentan una mejor respuesta al ruido y obtienen un buen rendimiento tanto en sistemas supervisados como no supervisados.

Para el modelado basado en datos, se utilizan plataformas en la nube proporcionadas por grandes compañías (IBM Digital Twin Exchange, Microsoft Azure Digital Twin, o Siemens PLM), las cuales cuentan con modelos estandarizados de los diferentes sistemas. Pero su utilización en las plantas está condicionada a pagos de licencia, así como acceso a la Nube. En el presente trabajo se propone mediante la utilización de un Autoencoder, con capas combinadas de redes neuronales convolucionales (CNN) y Long short-term memory (LSTM), una arquitectura que permita la obtención del objetivo propuesto.

El objetivo principal de este trabajo es obtener el Gemelo Digital de un PSFV mediante la utilización de una arquitectura de autoencoder, y su utilización para detectar anomalías,

realizando un análisis de las series temporales del mismo. Para este propósito se plantean los siguientes objetivos particulares:

- Realizar el procesamiento de los datos obtenidos (Series Temporales) en un PSFV.
- Realizar un análisis de los mismos, tanto en el dominio de la frecuencia como en el dominio del tiempo, con el fin de estudiar su influencia en la obtención del DT.
- Diseñar una arquitectura de aprendizaje profundo que permita la obtención del Gemelo Digital.
- Comprobar la fiabilidad de este Gemelo Digital mediante un sistema de detección de anomalías.

El presente trabajo se organiza en 3 capítulos. En el Marco Teórico (sección 2) se describen los principales fundamentos teóricos para la solución del problema. En el capítulo de Metodología (sección 3) se detallan aspectos del análisis y desarrollo del trabajo. En capítulo de Resultados (sección 4) se realiza una serie de experimentos con diferentes conjuntos de datos y se realiza un análisis de los resultados obtenidos. Por último, se presentan las conclusiones y se plantean ideas para trabajo futuro.

2. MARCO TEÓRICO

En esta sección se describen los principales fundamentos teóricos para el desarrollo del presente trabajo. En la sección inicial, se describen las series temporales, así como algunas técnicas utilizadas para su procesamiento. Además, se exponen los algoritmos utilizados de aprendizaje profundo para sistemas no supervisados y finalmente se da un bosquejo sobre los gemelos digitales, los sistemas de detección de anomalías y su aplicación en los sistemas de energía fotovoltaica.

2.1. Series Temporales

Las series temporales se utilizan para estudiar las relaciones entre las variables y el paso del tiempo. Estas están presentes en muchos dominios de aplicación, como las finanzas, medicina e ingeniería. Actualmente con el surgimiento de la IoT, la recopilación de mediciones de sensores en este formato es imprescindible para los sistemas de predicción y seguimiento, así como su utilización en los sistemas en la nube, para la obtención como operación de los DT.

Una serie temporal no es más que la sucesión de datos observados en periodos de tiempo y ordenados cronológicamente [3]. Estas nos permiten estudiar las relaciones entre variables que cambian en el tiempo y su influencia entre sí. Las mismas pueden clasificarse como uni-variable y multi-variable:

- Definición 1. Una serie temporal uni-variable $X = \{x_t\}_{t \in T}$, es un conjunto ordenado de observaciones reales, donde cada observación corresponde a un tiempo $t \in T \subseteq \mathbb{Z}^+$.
- Definición 2. Una serie temporal multi-variable $X = \{x_t\}_{t \in T}$, es definida como un conjunto ordenado de vectores k -dimensionales, donde cada vector es observado en un tiempo específico $t \in T \subseteq \mathbb{Z}^+$ y consiste en k observaciones reales, $x_t = \{x_{1t}, \dots, x_{kt}\}$.

En el caso de las series multi-variable es importante recalcar que cada vector no depende solamente de sus valores pasados sino también del resto de los vectores temporales. A continuación, se analizan algunas de las técnicas empleadas para el estudio de las series temporales, tanto en el dominio del tiempo como de la frecuencia.

2.1.1 Análisis en el dominio del tiempo

Para cualquier sistema es crucial el análisis en el dominio temporal. El estudio de las diferentes características de los sistemas, así como la aplicación de diferentes técnicas nos permiten conocer información relevante sobre el sistema a estudiar, y extraer características que permitan identificar posibles patrones.

Entre estas técnicas, los métodos estadísticos son de relevante importancia. Características como la media, la desviación estándar y la varianza, nos proporcionan información sobre la tendencia, estabilidad y distribución probabilística de una señal.

Otras técnicas más sofisticadas como la curtosis, el coeficiente de asimetría (skewness) y la correlación, son utilizadas para conocer la normalidad de una señal, así como las relaciones entre esta y otras señales. A continuación, detallamos brevemente estas técnicas:

- Curtosis: Proporciona información de la forma de la distribución [4].
- Coeficiente de asimetría: Como indica su nombre nos informa sobre la asimetría de la distribución, siendo valores negativos indicativo de un sesgo a la izquierda y valores positivos indicativo de un sesgo a la derecha [4].
- Correlación: Medida de la relación lineal entre las señales. Muy utilizada para detectar señales altamente correlacionadas con el objetivo de realizar reducción de dimensionalidad [5].

La aplicación de estas técnicas en combinación con técnicas de suavizado, logra una mejor distribución en las señales, que repercuten en el rendimiento posterior del sistema. Existen diferentes técnicas de suavizado: exponencial, logarítmico, entre otras. El objetivo de estas es lograr una señal con una mejor distribución como se muestra en la Fig. 1.




Fig. 1 Efecto de suavizado exponencial, rojo: señal original, verde y azul diferentes suavizados [6].

La descomposición estacional es una de las técnicas más utilizada en el análisis de las series temporales. Esta técnica consiste en la descomposición en cuatro componentes: tendencia, caracteriza la tendencia al incremento, decremento o mantenerse estable de la serie temporal en un periodo largo de tiempo; cíclico, describe los cambios causados por circunstancias que se repiten de forma cíclica; estacionalidad, explica las fluctuaciones dentro de un año durante las estaciones; y residuo, variaciones irregulares causadas por influencias impredecibles. Usualmente utiliza dos modelos: el modelo aditivo $y_t = T_t + C_t + S_t + I_t$, el cual es aplicado cuando la magnitud de las fluctuaciones estacionales no varía en relación al nivel de la serie temporal; y el nivel multiplicativo $y_t = T_t * C_t * S_t * I_t$, cuando la variación en la estacionalidad es proporcional al nivel de la serie temporal [2].

Otras técnicas que nos permiten realizar un estudio profundo de las series temporales en el dominio del tiempo son la función de auto-correlación, auto-correlación parcial y los modelos autorregresivos, media móvil, autorregresivo de media móvil y autorregresivo integrado de media móvil. Cada una de estas técnicas nos proporcionan información sobre la predictibilidad de la serie temporal, como la influencia de procesos aleatorios o de la linealidad e influencia de valores anteriores. A continuación, detallamos brevemente estas técnicas:

- Función de Auto-correlación (ACF), no es más que simplemente la correlación de una serie temporal con una versión de la misma desplazada en el tiempo, nos proporciona una medición de la predictibilidad lineal de la serie temporal [8].
- Función Parcial de Auto-correlación (PACF), similar al anterior pero limitado a intervalos cortos de la serie temporal, nos permite una correcta estimación de parámetros a utilizar en modelos como ARMA o ARIMA [8].
- Modelo autorregresivo (AR), modelo lineal que utiliza las relaciones interdependientes entre una observación y un número de intervalos de observaciones desplazadas en el tiempo [8].
- Modelo media móvil (MA), modelo lineal que utiliza las relaciones interdependientes entre una observación y el error residual de la media aplicado a un número de intervalos de observaciones desplazadas en el tiempo [8].
- Modelo autorregresivo de media móvil (ARMA), combinación de los dos modelos anteriores, presenta como problemas principales redundancia de parámetros, así como dependencia de la estacionalidad de la serie temporal [8].
- Modelo autorregresivo integrado de media móvil (ARIMA), generalización del modelo anterior, incluye la I , correspondiente a la parte “integrada” que usa la diferenciación de las observaciones en aras de hacer la serie estacionaria [8].

2.1.2 Análisis en el dominio de la frecuencia

Las series temporales en muchas ocasiones son señales con presencia alta de ruido, el cual no es fácil procesar utilizando técnicas del dominio temporal. Por eso es recomendable la realización de un análisis en el dominio de las frecuencias primeramente para poder detectar la presencia de ruido, y mediante técnicas como la transformada de Fourier, descomponer la señal y observar la influencia del ruido en el espectro de las frecuencias.

A continuación, se detallan algunas técnicas:

- Amplitud vs Frecuencia: Permite observar la respuesta en frecuencia de una señal, lo cual ayuda a detectar la presencia de ruido en bajas o altas frecuencias.
- Espectrograma: Muestra la fortaleza de una señal a lo largo del tiempo de las diversas frecuencias en la señal. Permite detectar la presencia de armónicos en la señal.

En el dominio de la frecuencia, la aplicación de un proceso de filtrado es muy utilizado para la eliminación de la presencia de ruido. Entre los filtros más utilizados se encuentra el Butterworth y Chebyshev [8]. En la Fig. 2 se observa la comparación de respuesta en frecuencia de una señal a la cual se le aplicaron ambos filtros utilizando un filtrado pasa-bajo.

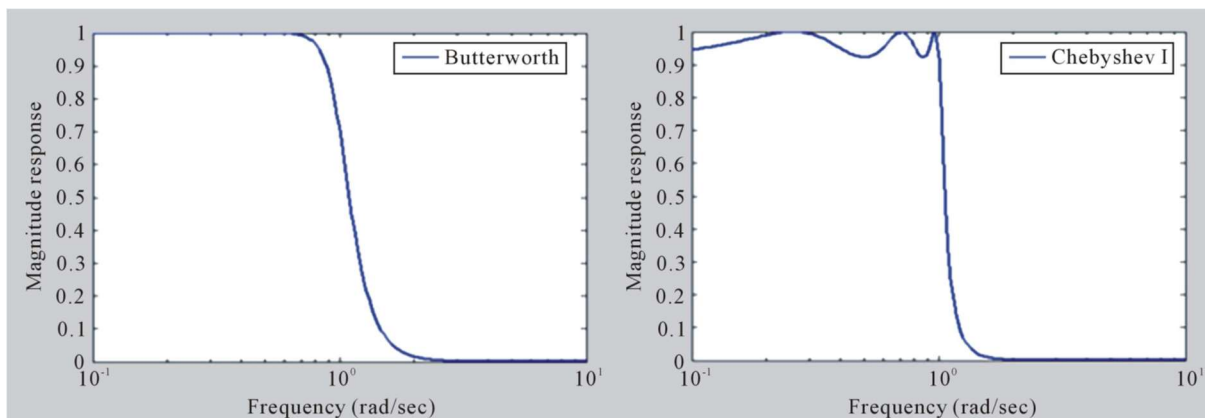


Fig. 2 Comparación de respuesta en frecuencia de filtro Butterworth y Chebyshev [9].

Como se observa en la imagen, en el filtro Butterworth la linealidad de fase es mejor que en el filtro Chebyshev, esto significa que la distorsión de la forma de onda de un filtro Butterworth es menor que en otros filtros. Por este motivo son muy utilizados como filtros de suavizado entre otras funciones [9].

2.2. Aprendizaje Profundo

El desarrollo de las investigaciones en el ámbito del aprendizaje profundo ha permitido un avance significativo en el desarrollo de diversos algoritmos de redes neuronales. Desarrollar algoritmos que permitan de una forma más eficiente resolver problemas tanto de aprendizaje supervisado como no supervisado ha sido uno de los objetivos del aprendizaje profundo [10].

Entre estos algoritmos se destacan por su amplia utilización las redes convolucionales (CNNs) [11], las cuales han demostrado su eficacia en diversas áreas, específicamente la visión por ordenador, donde es necesario extraer las características en estructuras espacio-temporales para el reconocimiento de patrones en las señales. Este tipo de redes han demostrado su utilidad dentro de arquitecturas más complejas, usualmente combinadas con otros tipos de redes, en sistemas donde la necesidad de reconocer patrones en las señales sea necesaria [10].

Otras arquitecturas más enfocadas en “aprender” las relaciones que se establecen en las series temporales son las LSTM (long short-term memory) [12]. Estas poseen un novedoso mecanismo de memoria para la modelación de dependencias a largo plazo, resolviendo el problema del desvanecimiento del gradiente en redes recurrentes más sencillas. Esto las convierte en una de las redes más utilizadas en problemas donde es necesario aprender las relaciones temporales que existen entre diferentes vectores [13].

Dentro de los algoritmos de aprendizaje no supervisado con más éxito se encuentran los autoencoders. Estos son un tipo de redes neuronales de aprendizaje profundo que mediante el uso de una reducción no lineal de la dimensionalidad son capaces de aprender las representaciones de los datos de una forma no supervisada. De esta forma la red puede “auto aprender” la representación de parámetros óptima que represente el conjunto de datos. Esta funcionalidad ha encontrado un uso extensivo en diferentes aplicaciones, siendo una de ellas la detección de anomalías [10]. Mediante la utilización de datos normales para el entrenamiento; el autoencoder es capaz de aprender las correctas representaciones de un sistema, minimizando el error de reconstrucción y a su vez utilizándolo como criterio de evaluación de anomalías, siendo esta una forma sencilla en detectar una anomalía en un sistema.

En las siguientes subsecciones, se realiza un breve análisis de las redes neuronales brevemente descritas anteriormente.

2.2.1 Redes Convolucionales y Recurrentes

Entre los algoritmos de aprendizaje profundo existen múltiples variantes de redes neuronales. Entre estas las más utilizadas se encuentran las redes convolucionales y las redes recurrentes. En las siguientes secciones se hará un breve análisis de las dos últimas redes.

Redes Convolucionales

Una red neuronal convolucional es una red neuronal en la cual se utiliza una operación de convolución en lugar de operaciones de multiplicación de matrices en al menos una de sus capas [10]. Estas redes mediante la combinación de capas convolucionales, capas de agrupamiento (pooling) y capas densas, como se observa en la Fig. 3, son capaces de capturar correctamente las interdependencias espacio-temporales de un conjunto de datos.




Fig. 3 Ejemplo de arquitectura de una Red Neuronal Convolucional [14].

A continuación, se explica brevemente el funcionamiento de los dos primeros tipos de capas:

- **Capa Convolutiva:** En esta capa es aplicada una operación de convolución a la entrada de la misma mediante un kernel con el objetivo de extraer un mapa de características, se puede denotar de la siguiente manera, $s(t) = (x * w)(t) = \sum_{\alpha=-\infty}^{\infty} x(\alpha)w(t - \alpha)$, siendo x la entrada, w el kernel y la salida puede ser referida como mapa de características. Presenta como principales parámetros el número de filtros a aplicar y el tamaño del kernel.
- **Capa de agrupamiento (pooling):** Se aplica una función de agrupamiento reemplazando la salida de la red en cierta locación con un resumen estadístico de los puntos cercanos. Esta operación ayuda hacer la representación invariante a pequeñas variaciones en la entrada.
- **Capa densa o completamente conectada:** esta capa opera sobre una entrada aplanada donde cada entrada está conectada a todas las neuronas. Normalmente se utilizan al final de la arquitectura convolucional y son utilizadas con el objetivo de optimizar la puntuación de las clases.

Dentro de las capas convolucionales existen diferentes configuraciones, explicaremos brevemente las utilizadas en este estudio:

- Conv1D: Esta capa crea un kernel convolucional, que mediante una operación de convolución con la capa de entrada en una sola dimensión espacial o temporal, produce un tensor de salidas.
- Conv1DTranspose: Capa de convolución transpuesta (llamada también, deconvolución), surge por la necesidad de realizar una transformación en la dirección opuesta de una convolución normal. O sea, modifica la salida de una convolución para que mantenga la forma de la entrada, manteniendo el patrón de conectividad de la capa convolucional.

Redes Recurrentes

Las redes neuronales recurrentes (RNN), son una clase de redes neuronales capaces de procesar una secuencia de entrada y retener su estado mientras procesan la siguiente secuencia de entrada [15]. Estas redes utilizan la compartimentación de parámetros para posibilitar la extensión del modelo a diferentes formas y generalizarlo.




Fig. 4 Arquitectura típica de una RNN [14].

Como se observa en la anterior figura, por cada instante de tiempo t , tenemos la activación $\alpha^t = g_1(W_{aa}\alpha^{t-1} + W_{ax}x^t + b_a)$, y la salida $y^t = g_2(W_{ya}\alpha^t + b_y)$, donde $W_{ax}, W_{aa}, W_{ya}, b_a, b_y$ son coeficientes compartidos y g_1, g_2 son funciones de activación.

Estas redes presentan el problema del desvanecimiento del gradiente. La razón de la ocurrencia de este fenómeno es que es difícil capturar las dependencias a largo plazo debido a que el gradiente puede aumentar o disminuir exponencialmente respecto al número de capas utilizadas. La manera más simple y efectiva de lidiar con este problema ha sido la utilización de las LSTM.

Propuestas por Hochreiter y Schmidhuber [12], las LSTM evitan el desvanecimiento del gradiente mediante la inclusión de una llamada “celda de estado”, cuya información es cuidadosamente regulada mediante estructuras llamadas compuertas. Las compuertas pueden ser denotadas de la siguiente manera: $\Gamma = \sigma(W_{x^t} + U_{a^{t-1}} + b)$, donde W, U, b son coeficientes específicos de la compuerta y σ es la función sigmoide.

En la Fig. 5 se muestran las dependencias entre la celda de estado $c^t = \Gamma_u \star \tilde{c}^t + \Gamma_f \star c^{t-1}$, el vector con los nuevos valores de la celda de estado $\tilde{c}^t = \tanh(W_c[\Gamma_r \star a^{t-1}, x^t] + b_c)$ y la activación a^t , donde Γ_u , es la compuerta de actualización; Γ_r , es la compuerta de relevancia; Γ_f , es la compuerta de olvido; Γ_o , es la compuerta de salida y W_c, b_c , son coeficientes de la celda de estado.




Fig. 5 Diagrama de una celda LSTM [14].

Otro punto a tener en cuenta en la implementación de cualquier red neuronal es evitar el sobreajuste. Para esto existen técnicas como los reguladores, para nuestro estudio explicaremos brevemente algunas de ellas:

- Dropout: Esta técnica previene el sobreajuste de la red neuronal eliminando neuronas de nuestra red con una probabilidad $p > 0$. Esto fuerza al modelo a evitar retransmitir en demasía un conjunto específico de características.
- L_1 (LASSO): Tipo de regularización que penaliza los pesos en proporción a la suma sus valores absolutos. En modelos con atributos dispersos ayuda a llevar a 0 a los atributos poco relevantes.

- L_2 (Ridge): En esta técnica se penalizan los pesos en proporción a la suma de los cuadrados de los pesos. Esta regularización ayuda a llevar a los pesos con valores atípicos cercanos a 0.

2.2.2 Autoencoders

Un autoencoder se define como una red neuronal entrenada para replicar una representación de su entrada en su salida. Internamente consta de dos partes (Fig. 6): una función encoder $h = f(x)$ que codifica el conjunto de datos de entrada en una representación del mismo, normalmente de menor dimensión, y una función decoder $r = g(h)$ que realiza la reconstrucción de la entrada a través de esta representación, tratando de disminuir el error de reconstrucción $ER(i) = \sqrt{\sum_{j=1}^D (x_j(i) - \hat{x}_j(i))^2}$. El proceso de aprendizaje puede ser definido con una función de pérdida a optimizar $L(x, g(f(x)))$ [10].




Fig. 6 Arquitectura de un autoencoder [16].

Un problema que ocurre a menudo con los autoencoders es que, aunque logran una correcta representación de la entrada no aprenden ninguna característica útil de los datos de entrada. Una de las opciones para evitar esta situación es añadir un regularizador al encoder, $L(x, g(f(x))) + \Omega(h)$. Esto permite no solamente disminuir el error de reconstrucción, sino también que aprendan características útiles.

Los autoencoders posibilitan desarrollar una arquitectura que puede reconstruir una representación fiable a partir de un conjunto de entrada, y a su vez logre aprender características relevantes sobre la misma [17]. Nos permite su utilización como base para lograr obtener la representación digital de un sistema a través del aprendizaje de sus datos históricos.

2.3 Gemelo Digital

Han surgido múltiples definiciones del Gemelo Digital, desde la primera mención del termino por Grieves [18]. En el estudio que hacen Fuller [19] y Barricelli [20], se abordan varias de estas definiciones y a través de ellas podemos llegar a la conclusión de que un gemelo digital, no es más que la réplica digital de un objeto o sistema físico, en constante evolución mediante una conexión al sistema físico.

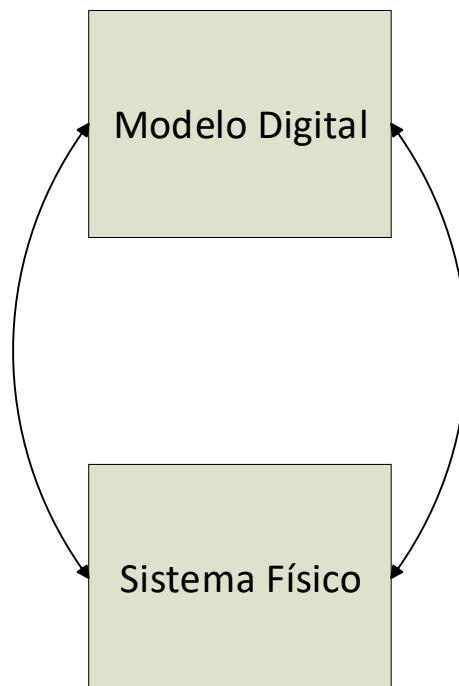


Fig. 7 Esquema de Gemelo Digital.

El desarrollo de las tecnologías como el Big Data, el IoT, la Industria 4.0, así como la utilización de la Inteligencia Artificial, han permitido el desarrollo de los DT mediante la implementación de modelos basados en datos utilizando algoritmos tanto de aprendizaje automático como profundo [21]. Estos modelos basados en datos presentan una alternativa donde se requiere un menor conocimiento de experto para su implementación.

La utilización de algoritmos de aprendizaje profundo para la obtención del DT de un sistema físico ha sido ampliamente estudiada, siendo dentro de estos algoritmos uno de los más analizados los autoencoders [21]. Esto se debe principalmente a su capacidad de poder construir representaciones basadas en relaciones lineales o no lineales, así como características presentes en su entrada.

Entre las muchas aplicaciones de los DT, se encuentra la detección de anomalías, mediante la comparación del DT obtenido en un comportamiento normal, el DT puede determinar si ocurre una desviación en el sistema físico que sea síntoma de la ocurrencia de una anomalía [22] y [23].

Detección de anomalías

La detección de anomalías es un área activa en la investigación de muchos campos como el análisis estadístico, el control de procesos, el procesamiento de señales y últimamente en el aprendizaje automático y profundo. Desde un punto de vista estadístico podemos decir que una anomalía es un valor atípico en una distribución [24].

Estas pueden ser clasificadas en tres tipos de anomalías:

- Anomalía puntual: Si un dato puntual puede ser considerado anómalo respecto al resto del conjunto de datos, entonces estamos en presencia de una anomalía puntual [25].
- Anomalía contextual: Si la instancia del dato es considerado anómalo de acuerdo a un contexto específico, pero no de otra forma, entonces estamos en presencia de una anomalía contextual [25].
- Anomalía colectiva: Si una colección de datos es considerado anómalo con respecto al conjunto de datos entonces estamos en presencia de una anomalía colectiva [25].

Cuando el sistema de detección es supervisado, la utilización de técnicas de aprendizaje automático ha demostrado su eficacia. Este rendimiento de los algoritmos de aprendizaje automático decae cuando es necesario capturar las complejas relaciones estructurales en grandes conjuntos de datos [24]. Para el análisis de conjuntos multi-variables y de alta dimensionalidad, estudios como el de Blázquez-García [3] o el de Chalapathy [24], demuestran que mediante la utilización de técnicas de aprendizaje profundo se pueden capturar esas relaciones estructurales complejas en conjuntos de datos con esas características.

Entre las técnicas de aprendizaje profundo que han logrado obtener buenos resultados en los sistemas de detección de anomalías se encuentran los autoencoders. Pero existen pocos estudios que vinculen su utilización en la obtención del DT para su uso en la detección de anomalías [19]. El estudio desarrollado por Boyse [22], demuestra la efectividad en el diagnóstico utilizando técnicas de aprendizaje profundo para la obtención del DT, y su posterior uso en la detección de posibles averías.

Para la detección de anomalías en conjuntos como el anteriormente descrito se utilizan tres técnicas de detección principalmente: la detección secuencial, espacial o gráfica [25]. La detección secuencial se aplica a conjuntos de datos secuenciales (ejemplo, series temporales) con el fin de determinar las sub-secuencias que puedan ser anómalas [26].

Estas técnicas de detección varían en su implementación y criterios de acuerdo al dominio de aplicación. Uno de los métodos más generales utilizados para determinar un valor o puntuación anómala es mediante el cálculo del error de reconstrucción (*ER*) [24]. Mediante la utilización de un conjunto de entrenamiento con muestras normales, se obtiene el mínimo *ER*, el cual es utilizado como umbral de anomalía; ya sea para obtener la valoración de la anomalía o su etiquetado.

2.4 Escenario de aplicación: Parques solares fotovoltaicos

En el presente trabajo se utilizó como marco de aplicación un Parque Solar Fotovoltaico ubicado en la región oriental de Cuba. El PSFV suministrado por la firma C.R. Technology Systems SPA, cuenta con la tecnología de inversor suministrada por SMA Solar Technology AG. La obtención de los datos de operación de uno de sus inversores en un periodo de tiempo de nueve meses posibilitó la realización de este estudio. En la Fig. 8 se muestra el esquema operacional del PSFV.

Un PSFV consiste en una instalación solar de gran escala donde mediante la instalación a nivel del suelo de los paneles solares u otros medios se realiza la captación de la energía solar. Funcionan como una central eléctrica u otras fuentes de energía, pero a diferencia de estas están descentralizados. Mediante el agrupamiento de diferentes subconjuntos de paneles en arreglos (array) y estos en cadenas de arreglos (string array), se recolecta la energía a través de los monitores de cadenas y se envía al inversor para su conversión y sincronización a la red eléctrica [27]. Siendo todo este proceso monitoreado por personal de operación a través del SCADA.




Fig. 8 Esquema general de un PSFV.

Como se observa en el esquema presentado en la figura anterior, un PSFV consta de forma general de cinco componentes principales:

- Paneles o placas solares: Conjunto de celdas solares conectadas ya sea en serie o paralelo. Convierte la energía solar en energía eléctrica. Están organizados en formas de arreglos o matrices (arrays). Y estos conjuntos de arrays a su vez están organizados en cadenas (strings). En nuestro sistema, cada panel solar contiene 60 celdas solares en serie, ocho de estos paneles forman un arreglo (array), y ocho de estos arreglos forman una cadena (string).
- Monitor de String: Realiza el seguimiento del comportamiento de cada string conectado a él. En nuestro sistema realiza el seguimiento en ocho strings de variables como corriente, voltaje y temperatura; transmitiendo las mismas al inversor.
- Estación meteorológica: Recoge mediante diversos sensores las mediciones de las condiciones climáticas, irradiación, temperatura, velocidad del viento humedad, entre otras. Estas mediciones son enviadas al inversor mediante una red RS-485.
- Inversor: Recibe la corriente continua, así como las mediciones de cada monitor de string conectado a él, en nuestro sistema el máximo de monitores es 8, convirtiendo esta corriente continua en corriente alterna. Realiza un seguimiento de las condiciones de cada componente y trasmite su estado al sistema de control.
- SCADA: Acrónimo de Control Supervisor y Adquisición de Datos. Sistema encargado de recoger y visualizar el estado de las mediciones de todos los equipos del PSFV al operador.

En nuestro estudio se propone la obtención del DT del inversor de un PSFV. Esto se debe a que el inversor además de ser el segundo equipo más importante en un parque solar, es el que presenta una incidencia más alta de averías por influencia de factores tanto externos como internos. Su función doble función de convertir la energía y concentrar las señales, tanto de medición como de generación, nos proporciona una visión general de lo que está ocurriendo en el PSFV.

Existen pocas referencias a estudios donde se proponga la utilización de algoritmos de aprendizaje profundo para la obtención del DT de un inversor. Estudios como los realizados por Barricelli [20], o Qinglin [28], documentan la casi inexistencia de artículos donde se combinen la utilización de técnicas de modelado por datos y algoritmos de aprendizaje profundo para la obtención de DT.

A continuación, en la Tabla 1. se presentan las características del inversor de la firma SMA, modelo Sunny Central 1000CP XT.

CARACTERÍSTICAS	MODELO SC-1000CP-XT
POTENCIA DE CC (KW)	1122
VOLTAJE CC DE ENTRADA (V)	1000
$V_{MPP_m\grave{A}x} \alpha I_{MPP} < I_{CCm\grave{A}x}$ (V)	596
CORRIENTE DE CC DE ENTRADA (A)	1635
NÚMERO DE ENTRADAS DE CC	9
POTENCIA DE AC (KVA)	1100 (a 25 grados Celsius)
VOLTAJE DE AC (V)	365 a 465
CORRIENTE DE AC (A)	1568

Tabla 1. Características del Inversor.

2.5 Tecnologías utilizadas

Para llevar a cabo las implementaciones, se utiliza como lenguaje de programación Python3 junto con un conjunto de librerías y herramientas específicas dentro del área del aprendizaje automático y profundo, así como también la utilización de un IDE de desarrollo gratuito, a continuación, se mencionan algunas:

- **Visual Studio Code:** editor de programación multiplataforma desarrollado por Microsoft. Gratuito y de código abierto fue publicado por Microsoft en el 2015. Ofrece compatibilidad con varios lenguajes de programación y mediante el uso de extensiones permite tanto el desarrollo de script en Python como el uso de Jupyter Notebooks (<https://code.visualstudio.com>).
- **Numpy:** es una biblioteca para computación científica en Python. Proporciona variedad de rutinas para operaciones rápidas en vectores y matrices; como manipulación de formas, transformadas de Fourier, algebra lineal clásica, y operaciones estadísticas entre otras (<https://numpy.org>).
- **Pandas:** es una biblioteca para manipulación y análisis de datos en el lenguaje de programación Python. En particular, ofrece estructuras de datos y operaciones para manipular tablas numéricas y series temporales y herramientas para su manipulación (<https://pandas.pydata.org>).
- **Statsmodels:** es un módulo de Python que proporciona clases y funciones para la estimación de diferentes modelos estadísticos. Permite realizar tanto exploración de datos estadísticos como la realización de diferentes pruebas estadísticas (<https://www.statsmodels.org>).
- **Scikit-Learn:** es un conjunto de librerías para aprendizaje automático, presenta algoritmos para pre-procesamiento, clasificación, regresión y clustering. El módulo de pre-procesamiento incluye variedad de funciones y clases que permite la transformación de los datos en una representación más adecuada para su procesamiento (<https://scikit-learn.org>).
- **Tensorflow:** Framework desarrollado originalmente por investigadores e ingenieros del equipo Brain de Google dentro de la organización de investigación en Inteligencia Artificial de Google para investigaciones y desarrollo de aprendizaje automático y redes neuronales profundas. (<https://www.tensorflow.org>).

3. METODOLOGÍA

En esta sección se detallan todo el análisis y proceso de implementación que se ha llevado a cabo en el presente trabajo. En la Fig. 9 se muestra el diagrama del procesamiento efectuado en el presente trabajo.

Primeramente, se extrae del Inversor los archivos CSV, con la información recopilada diariamente. A continuación, se hace un pre-procesamiento con el objetivo de disminuir la dimensionalidad. Posteriormente se realiza un análisis de características en los dominios tiempo y frecuencia, para estudiar su posible impacto en el rendimiento del modelo propuesto. Para obtener el gemelo digital, se propone la utilización de un autoencoder. Por último, se utiliza el error de reconstrucción del gemelo digital obtenido como referente para el sistema de detección de anomalías.

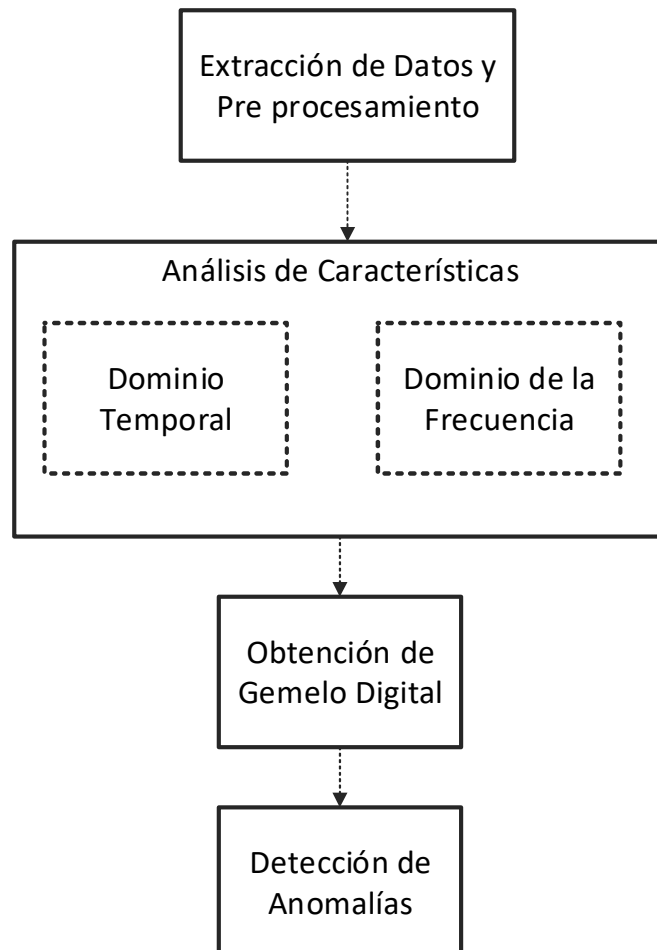


Fig. 9 Metodología para el procesamiento.

Datos a analizar:

El conjunto de datos de partida fue obtenido de un Inversor de la firma SMA modelo SC-1000CP-XT, en el periodo de tiempo entre el 01-07-2019 hasta el 16-03-2020, y consta de un archivo CSV diario con 288 mediciones de 259 métricas distintas.

3.1 Pre-procesamiento y Análisis de Métricas

Inicialmente se realiza la lectura de los archivos CSV proporcionados por los operarios de la planta. Como primer paso se procede a la creación de un DataFrame que contenga el conjunto de mediciones recogidas en cada CSV con el objetivo de facilitar su posterior tratamiento. A continuación, se procede a la eliminación de las métricas categóricas, pues no proveen información que pueda ser utilizada para la obtención del gemelo digital.

Con el objetivo de transformar el conjunto de datos, se realiza un tratamiento con el objetivo de tratar con datos tanto erróneos como faltantes. A continuación, se realiza el procesamiento de las métricas que contienen la información temporal, estableciendo un índice temporal con una frecuencia de muestreo de 5 minutos, así como se seleccionó solamente la franja horaria correspondiente a la incidencia de luz solar.

Mediante la utilización del método Kendall se calcula la correlación entre las diferentes señales, eliminando las señales altamente correlacionadas (con un índice superior a 0.9), con el objetivo de disminuir la dimensionalidad del conjunto.

Se realiza un estudio por subconjuntos, dividiendo las señales principales (las que son entradas o salidas directas al Inversor) en un subconjunto y las restantes, coincidentes con las corrientes de String, se separan en dependencia de su monitor de Strings (8 señales por monitor, 14 monitores en total).

Se realiza un análisis de cada subconjunto detectándose la ausencia de al menos el 70 % de mediciones en el 50 % de los subconjuntos correspondientes a los monitores de String. En base a estos datos se determinó la eliminación de estos subconjuntos, seleccionándose para el estudio el subconjunto con las señales principales.

En la Tabla 2 se proveen el significado de estas métricas.

MÉTRICA	SIGNIFICADO
Pac	Potencia activa de CA en kW
Qac	Potencia reactiva en kVAr
Sac	Potencia aparente en kVA
Iac	Corriente de red en A
Vac	Tensión de red en V
Ppv	Potencia fotovoltaica en kW
Ipv	Corriente fotovoltaica en A
Vpv	Tensión fotovoltaica en V
Riso	Resistencia de aislamiento
MeanCurvGR1	Media total de la corriente fotovoltaica de string

Tabla 2. Métricas seleccionadas para el estudio.

A continuación, se realizó un análisis de características en el dominio temporal y de la frecuencia, para determinar que posible impacto tendrían en la obtención del gemelo digital utilizando el error cuadrático medio (MSE).

3.2 Análisis en el Dominio Temporal

Se seleccionaron inicialmente las siguientes cuatro características para el análisis: la media, varianza, curtosis y skewness, con el objetivo de determinar la distribución del conjunto de datos, su simetría y presencia de sesgo, detectándose una alta dispersión en las mediciones de las señales así como una fuerte presencia de sesgo en las mismas, como se observa en la Tabla 3.

MÉTRICAS	MEDIA	VARIANZA	CURTOSIS	SKEWNESS
Pac	322.90	82326.01	-1.33	0.38
Qac	0.58	0.48	0.06	1.03
Sac	322.85	82332.12	-1.33	0.38
Iac	481.59	181541.84	-1.33	0.37
Vac	387.52	126.26	555.89	-16.43
Ppv	336.74	88786.19	-1.32	0.38
Ipv	514.47	222093.56	-1.21	0.48
Vpv	622.47	31905.66	6.07	-2.67
Riso	159.47	26919.48	375.96	16.09
MeanCurvGR1	1.72	5.32	-0.34	1.06

Tabla 3. Valores de algunas características en las métricas.

Para lograr una distribución más normalizada, se realizó un suavizado logarítmico. A continuación, se realizó el test Augmented Dickey-Fuller con el objetivo de comprobar la estacionalidad de las señales, obteniendo un p-value igual a cero, por lo cual podemos aceptar la hipótesis de que nuestro conjunto de datos es estacional. Para comprobar la existencia de patrones en las diferentes señales se utilizó ACF y PACF, observando la presencia de un patrón de predictibilidad (ver ejemplo Fig. 10).




Fig. 10 Ejemplo de ACF y PACF en la señal Pac.

Posteriormente, se realizó una descomposición aditiva a cada señal, con el objetivo de separar la señal, de la estacionalidad, tendencia y residuos, generando un nuevo conjunto de datos solamente con la señal observada.

3.3 Análisis en el Dominio de la Frecuencia

Para realizar el análisis en el dominio de las frecuencias, inicialmente se procedió a obtener la transformada de Fourier del conjunto de datos. Se realizó un examen de la distribución de frecuencias de las señales, escogiendo como intervalo de tiempo para el estudio un día. En la Fig. 11 se muestra la normalidad de la señal en frecuencia de varios días de la señal Pac, para una mejor visualización se definieron varios percentiles (5, 10 y 15).

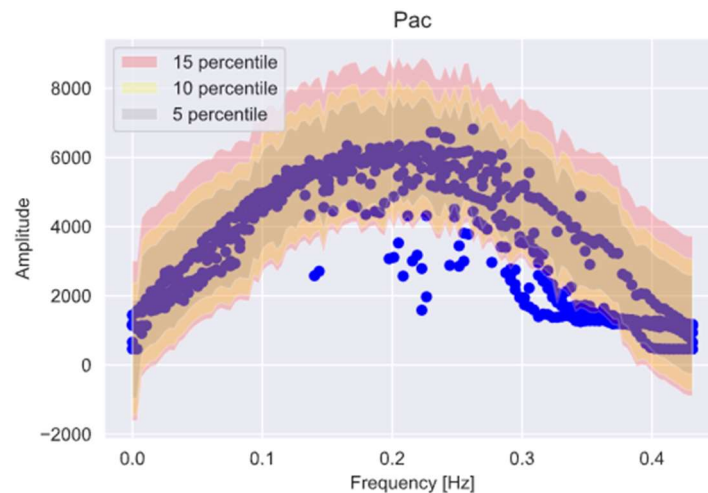


Fig. 11 Estudio de normalidad de Pac.

Para comprobar el efecto del posible ruido se realizó el procesamiento de las señales, aplicando un proceso de filtrado mediante el método Butterworth, utilizando dos procesos de filtrados para comprobar su incidencia en las señales, uno mediante un filtro pasa-bajo y otro mediante un filtro pasa-banda; obteniendo una señal más “limpia” en el caso del filtro pasa-bajo, como se observa en Fig. 12.

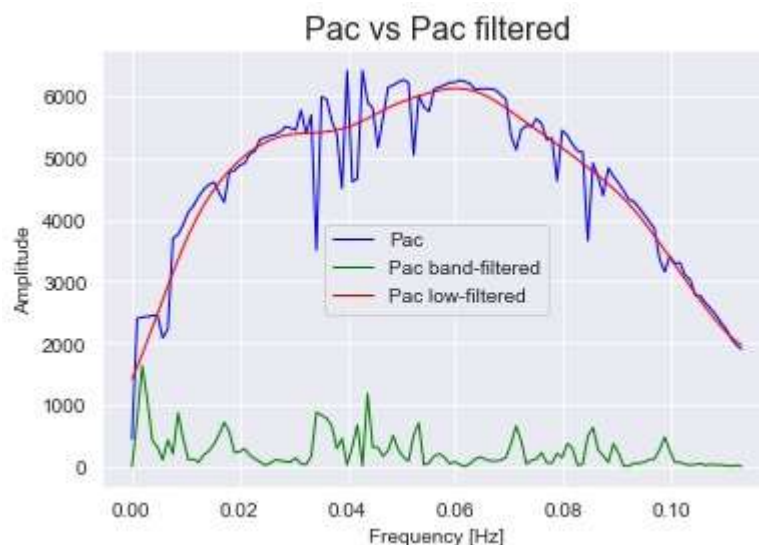


Fig. 12 Efecto del Filtro Pasa-bajo y Pasa-banda.

Como se observa en la figura anterior el filtro pasa-bajo logra una señal más suavizada, pero sin llegar a perder la forma de onda. Mediante la utilización de este proceso de filtrado se procedieron a generar un nuevo conjunto con las señales filtrada con un filtro pasa-bajo, para su utilización en la sección experimental y determinar su efecto en la detección de anomalías.

Combinación de Técnicas de suavizado en dominio del tiempo y de la frecuencia.

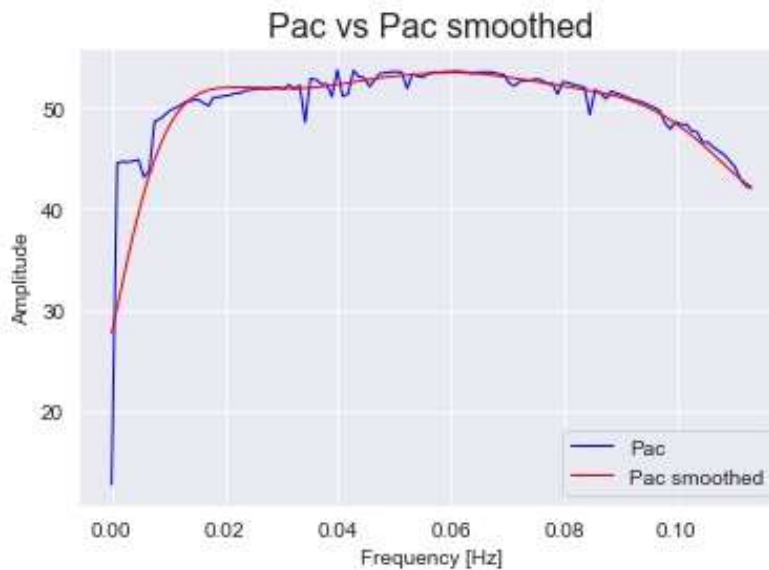


Fig. 13 Efecto de aplicación tanto en dominio temporal como de la frecuencia.

Para estudiar el efecto de la combinación de las técnicas de análisis y extracción de características expuestas anteriormente, se aplicaron estas técnicas al conjunto de datos original. Como se observa en la Fig. 13 se obtuvo una señal altamente suavizada, debido al efecto de inicialmente aplicar técnicas de suavizado logarítmico, posteriormente a esta señal suavizada mediante una descomposición estacional se eliminaron la incidencia de ruido en el dominio temporal, y por último se aplicó un filtro pasa-bajo para eliminar la incidencia de ruido en las bajas frecuencias.

3.4 Obtención del Gemelo Digital

Se propone la utilización de técnicas de Aprendizaje Profundo no supervisado, las cuales a través de los datos procesados y la arquitectura propuesta “aprenderán” el modelo del objeto estudiado, obteniendo de esta forma su gemelo digital, para su posterior utilización en la detección de anomalías en el sistema físico.

El modelo propuesto, Fig. 14, utiliza la arquitectura de un Autoencoder de la siguiente manera:

- Encoder:
 - Capa Convolucional Conv1D: el objetivo de esta capa es extraer las características más significativas del conjunto de datos.
 - Capa Convolucional Conv1dTranspose: el objetivo de esta capa es retomar la configuración de la entrada manteniendo las características aprendidas por la capa anterior.
 - Capa Recurrente LSTM: Mediante la utilización de esta capa se pretende que la red sea capaz de aprender las relaciones temporales que se establecen entre un conjunto de datos multivariable.
 - Capa de reorganización RepeatVector: Esta capa es usada como un adaptador que permite concatenar la salida del Encoder con la entrada del Decoder.
- Decoder:
 - Capa Recurrente LSTM: Mediante la utilización de esta capa se pretende que la red sea capaz de decodificar las relaciones temporales que se establecen entre un conjunto de datos multivariable.
 - Capa Recurrente TimeDistributed: Esta capa es usada como contenedor de una capa Densa de forma de que cada peso puede producir una salida en cada instante de tiempo (timestep).

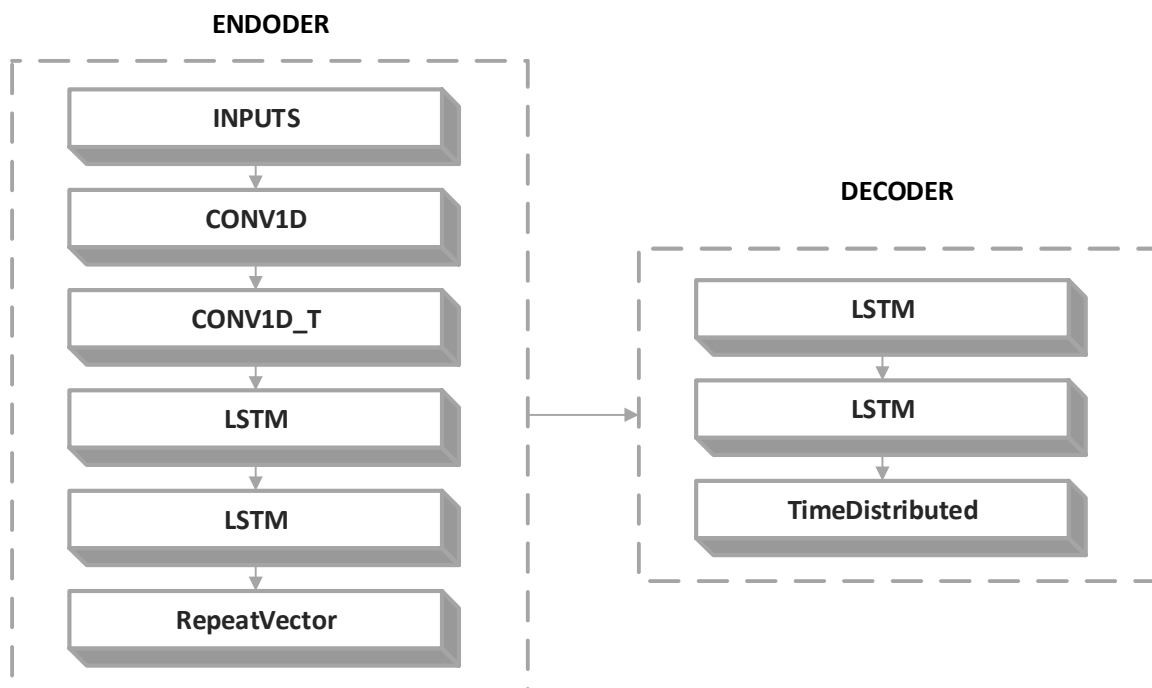


Fig. 14 Arquitectura propuesta.

A continuación, se muestra las características de la arquitectura propuesta:

- Encoder:
 - Entrada:
 - Forma: time steps x métricas.
 - Convolutacional 1D:
 - Numero de filtros: 64.
 - Tamaño del Kernel: 7.
 - Función de Regularización: L2 = 0.0001.
 - Función de Activación: 'relu'.
 - Dropout:
 - Frecuencia: 0.2.
 - Transpuesta de la Convolutacional 1D:
 - Numero de Filtros: métricas.
 - Tamaño del Kernel: 7.
 - LSTM:
 - Número de capas: 2.
 - Número de unidades de salida: 128 y 64, respectivamente.
 - Función de Activación: 'relu'.
 - RepeatVector:
 - Factor de repetición: métricas.
- Decoder:
 - LSTM:
 - Número de capas: 2.
 - Número de unidades de salida: 64 y 128, respectivamente.
 - Función de Activación: 'relu' y 'softmax', respectivamente.
 - TimeDistributed:
 - Capa: Densa (Número de unidades = métricas).

Con 262 740 parámetros a entrenar, se utilizó para el entrenamiento la siguiente configuración:

- Épocas: 50.
- Tamaño del Batch: 128.
- Optimizador: Adam.
- Tasa de Aprendizaje: 0.001.
- Función de Perdida: Error cuadrático medio (MSE).

3.5 Detección de anomalías

Se propone mediante la utilización del gemelo digital, obtener la reconstrucción de las señales del sistema, así como su error de reconstrucción para ser capaces de establecer utilizar este error de reconstrucción como umbral para la detección de anomalías. Se utilizaron dos metodologías basadas en la detección de anomalías utilizando el ER , detalladas brevemente a continuación:

- Primer Método: Se establecen un conjunto de umbrales utilizando como criterio del grado de desviación δ hasta un 15 % de variación respecto al ER :
 - Si $\delta > ER \rightarrow$ anomalía leve.
 - Si $0.1 * \delta > ER \rightarrow$ anomalía seria.
 - Si $0.15 * \delta > ER \rightarrow$ anomalía grave.
- Segundo Método: Se define como umbral el ER y se establecen los siguientes criterios para el etiquetado de la anomalía:
 - Si al menos el 80 % de las señales en el mismo instante de tiempo t presentan $\delta > ER$
 - Y si la desviación δ se ha repetido en al menos $\pm 5t \rightarrow$ anomalía grave.

A continuación, se describen los pasos implementados para el sistema detección de anomalías:

1. Obtener el conjunto de reconstrucción $\hat{X}_t = \{\hat{x}_{1t}, \dots, \hat{x}_{kt}\}$ con la predicción de nuestro modelo utilizando el conjunto de entrenamiento $X_t = \{x_{1t}, \dots, x_{kt}\}$.
2. Con este conjunto de reconstrucción se obtiene el error de reconstrucción ER sobre el conjunto de entrenamiento.
3. Obtener el conjunto de reconstrucción $\hat{X}_t = \{\hat{x}_{1t}, \dots, \hat{x}_{kt}\}$ con la predicción de nuestro modelo utilizando el conjunto de prueba $X_t = \{x_{1t}, \dots, x_{kt}\}$.
4. Sobre el conjunto \hat{X}_t aplicar el método 1.
5. Sobre el conjunto \hat{X}_t aplicar el método 2.

Posteriormente se realiza una evaluación de la efectividad en la detección de anomalías de los modelos obtenidos mediante las distintas técnicas de procesamiento. Para ello se utilizó un conjunto de muestras etiquetadas manualmente de acuerdo al criterio de expertos y mediante la utilización de métricas como la precision, recall o AUC, se realiza la evaluación de los métodos propuestos.

4. RESULTADOS

En esta sección se muestran y analizan los resultados de los experimentos realizados. Inicialmente se muestran las características de los subconjuntos resultantes de aplicación de las etapas tanto de pre-procesamiento, como de análisis en el dominio del tiempo y de la frecuencia. Posteriormente se analiza su impacto en la obtención del gemelo digital, así como se validan en la detección de anomalías.

4.1 Configuración de los experimentos

Para el proceso experimental se obtuvieron cuatro conjuntos de datos obtenidos de la etapa de pre-procesamiento, análisis en el dominio del tiempo y frecuencia. En el proceso de validación se ha realizado experimentos con cada conjunto con el fin de establecer una comparación de su influencia, tanto en la obtención del gemelo digital como en la detección de anomalías. A continuación, se describen cada configuración experimentada.

En la Tabla 4 se muestran las características de los conjuntos de datos para el proceso de experimentación. Cada subconjunto de entrenamiento, validación y test, fue seleccionado en determinados intervalos de tiempo en los cuales mediante un análisis de experto se observa una mayor o menor presencia de anomalías (entrenamiento y validación: menor presencia de anomalías, prueba: mayor presencia de anomalías).

Tabla 4. Características de los conjuntos de datos.

	Intervalos	Muestras
Entrenamiento	'2019-10-10' : '2019-12-17'	8349
Validación	'2019-08-27' : '2019-09-27'	3872
Prueba	'2019-12-21' : '2020-03-15'	10406

Estudios de características

Se realiza un estudio de las características de las series temporales y su influencia en el modelo propuesto, utilizando como criterio de rendimiento el error de reconstrucción y el análisis empírico de la detección de anomalías en cada conjunto de prueba. En la Tabla 5 se especifican las distintas técnicas de procesamiento para cada conjunto de datos obtenidos.

Tabla 5 Técnicas de procesamiento aplicadas.

	Técnicas
Pre-procesamiento	<ul style="list-style-type: none"> • Limpieza de datos. • Reducción de la dimensionalidad.
Tiempo	<ul style="list-style-type: none"> • Suavizado Logarítmico • Descomposición Estacional
Frecuencia	<ul style="list-style-type: none"> • Filtro Pasa-bajo
Combinación tiempo-frecuencia	<ul style="list-style-type: none"> • Suavizado Logarítmico • Descomposición Estacional • Filtro Pasa-bajo

4.2 Obtención del Gemelo Digital

A continuación, se muestran los resultados obtenidos en cada experimento, con los diferentes conjuntos así se muestra a modo de ejemplo la detección de anomalías como es afectada por cada procesamiento realizado.

4.2.1 Experimentos con pre-procesamiento

En la Tabla 6 se muestran los resultados obtenidos utilizando solo el pre-procesamiento de los datos, así como, en la Fig. 15 se muestra gráfica de pérdida (loss) de los conjuntos de entrenamiento y validación. Como se observa, la arquitectura propuesta obtiene buenos resultados con una pérdida sobre los 0.01 y un error de reconstrucción por debajo de 0.1 para el conjunto de prueba. Se observa en la figura que sistema converge rápidamente a partir de la décima época.

Tabla 6. Resultados para conjunto con pre-procesamiento.

	Pérdida (loss)	Error de Reconstrucción
Entrenamiento	0.0061	0.0441
Validación	0.0057	
Prueba	0.0196	0.1074




Fig. 15 Grafica de Perdida.

En la Fig. 16 se muestran la señal original y la reconstruida por el DT, como se observa se logra reconstruir la señal a pesar de las oscilaciones producidas por la influencia del clima, evidenciando que la inclusión de las variables meteorológicas hubiera logrado una mejora respuesta del modelo. Esto evidencia que la utilización de un autoencoder para obtener el gemelo digital, proporciona robustez al sistema ante la presencia de señales con ruido en el sistema físico.




Fig. 16 Comparación entre señales; azul: Pac original, rojo: Pac reconstruida.

4.2.2 Experimentos en Dominio del tiempo

En la Tabla 7, se muestran los resultados obtenidos mediante la aplicación de técnicas en el dominio temporal. Así en la Fig. 17 se muestra gráfica de pérdida (loss) de los conjuntos de entrenamiento y validación. Como se observa, la aplicación de técnicas de suavizado logarítmico, así como descomposición estacional, no provocan una mejor respuesta en el rendimiento del modelo, aunque como se observa en la figura, el modelo tiende a converger después de la décima época.

Tabla 7. Resultados para conjunto con procesamiento en dominio del tiempo.

	Perdida (loss)	Error de Reconstrucción
Entrenamiento	0.0089	0.0698
Validación	0.0086	
Prueba	0.0374	0.1707

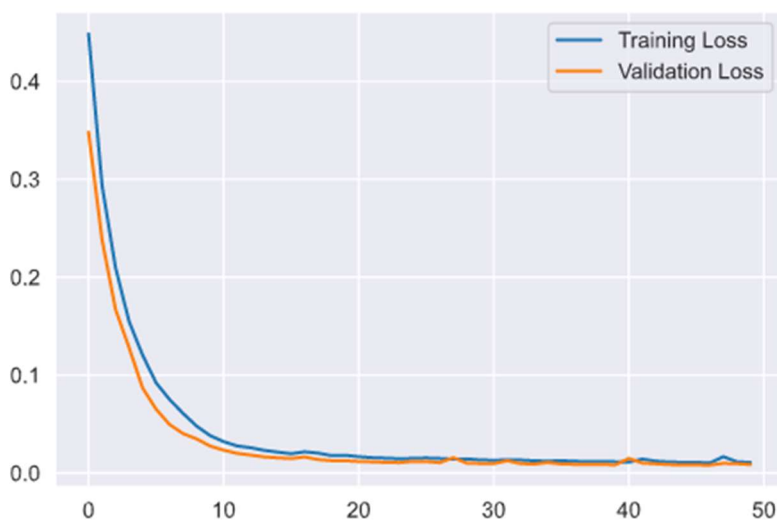


Fig. 17 Gráfica de Perdida con efecto de técnicas del dominio temporal.

La normalización de los datos, lograda a través del suavizado logarítmico, así como la eliminación mediante la descomposición de la señal del residuo, tendencia y estacionalidad, mejoran visiblemente la señal reconstruida como se observa en la Fig. 18. Estas técnicas logran que la señal reconstruida por el modelo sea más estable ante la presencia de ruido.

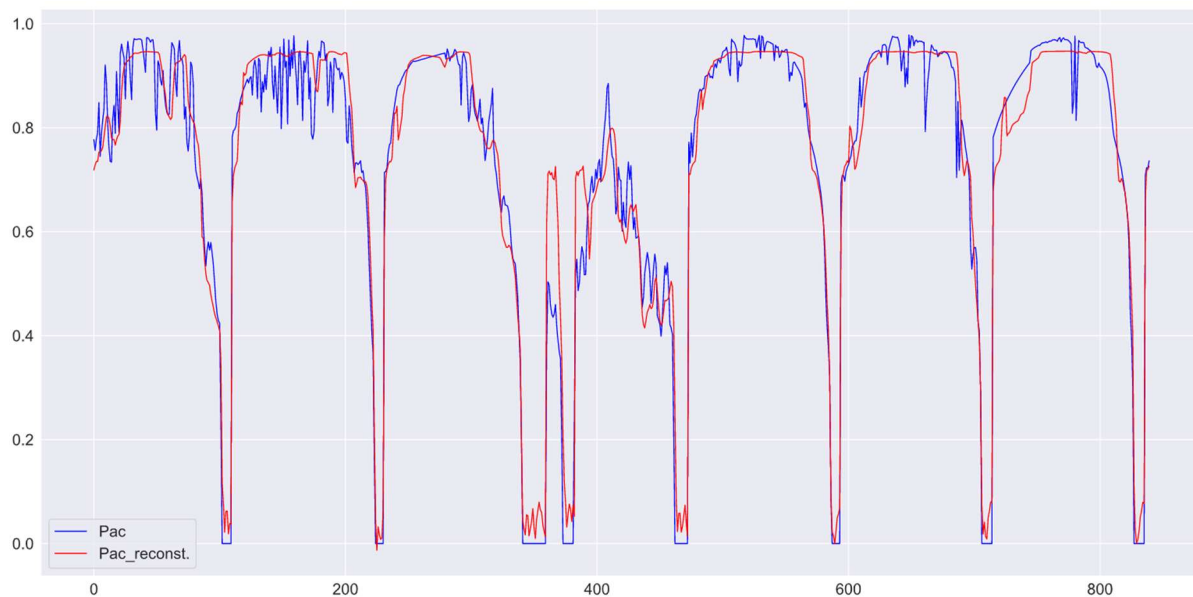


Fig. 18 Comparación entre señales; azul: Pac original, rojo: Pac reconstruida.

4.2.3 Experimentos en Dominio de la frecuencia

En la Tabla 8, se muestran los resultados obtenidos de la aplicación de un proceso de filtrado en el dominio de la frecuencia mediante un filtro Butterworth pasa-bajo . Así en la Fig. 19 se muestra el grafico de pérdidas de los conjuntos de entrenamiento y validación. El resultado de la aplicación de las técnicas en el dominio de la frecuencia, como se evidencia mejora sustancialmente los valores de perdida y error de reconstrucción del modelo. Es importante observar también como en la gráfica de perdida el sistema ya comienza a converger aun antes de la décima época observando que ya prácticamente posterior a la época 20 el sistema convergió completamente.

Tabla 8. Resultados para conjunto con procesamiento en dominio de la frecuencia.

	Perdida (loss)	Error de Reconstrucción
Entrenamiento	0.0020	0.0362
Validación	0.0014	
Prueba	0.0047	0.0588




Fig. 19 Grafica de Perdida con efecto de técnicas en el dominio de la frecuencia.

En la Fig. 20 se puede observar el efecto en la reconstrucción de la aplicación del proceso de filtrado mediante un filtro pasa-bajo Butterworth. Como se observa en la figura, la señal de entrada no presenta las oscilaciones que se vieron en ejemplo anteriores, por lo que el sistema es capaz de reconstruirla de forma casi perfecta.

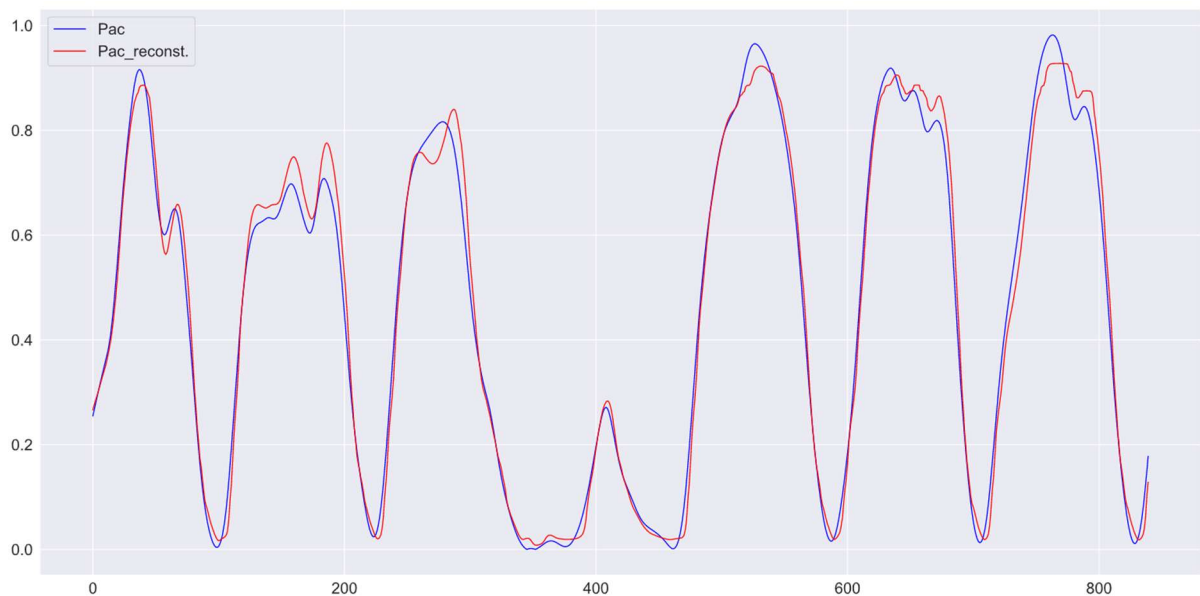


Fig. 20 Comparación entre señales; azul: Pac original, rojo: Pac reconstruida.

4.2.4 Experimentos en Dominio tiempo y frecuencia

En la Tabla 9, se muestran los resultados de la aplicación tanto de técnicas del dominio temporal como en el dominio de la frecuencia al conjunto de datos. Así como, en la Fig. 21 se muestra la gráfica de pérdida del modelo obtenido mediante el conjunto de datos tratado mediante la combinación de técnicas en el dominio temporal y de la frecuencia. Como se observa a pesar de obtener el menor error de reconstrucción en ambos conjuntos el comportamiento del modelo es similar. El efecto de la aplicación de técnicas en ambos dominios, logra un suavizado de la señal sin perder su forma de onda, logrando que el modelo sea capaz de aprender con una pérdida cercana a 0.

Tabla 9. Resultados para conjunto con procesamiento en dominio tiempo-frecuencia.

	Pérdida (loss)	Error de Reconstrucción
Entrenamiento	0.0021	0.0295
Validación	0.0022	
Prueba	0.0036	0.0439

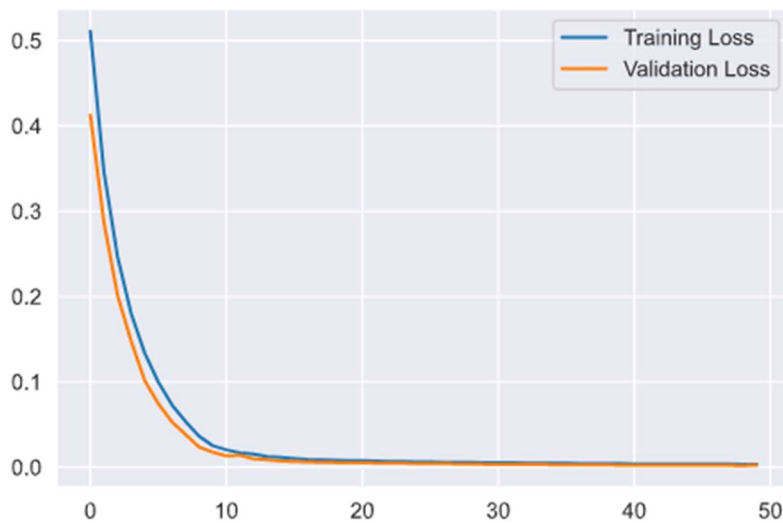


Fig. 21 Gráfica de Pérdida con efecto de técnicas en ambos dominios.

Como se observa en la Fig. 22 la señal reconstruida es similar al obtenido solo con las técnicas del dominio de la frecuencia, no observándose una variación significativa tanto en la señal original como en la reconstruida.




Fig. 22 Comparación de la reconstrucción con la aplicación de técnicas en tiempo y frecuencia.

4.3 Detección de anomalías

Como se observó en la sección anterior, la aplicación de diferentes técnicas tanto en el dominio temporal como en el de la frecuencia son capaces de lograr una mejora tanto en la pérdida del modelo como en el error de reconstrucción. Estas mejoras nos muestran que estas técnicas tienen una influencia en lograr que el proceso de aprendizaje del modelo sea lo más óptimo posible. Una de las vías para comprobar la eficacia y robustez del gemelo digital obtenido sería su utilización para la detección de anomalías. Para realizar este análisis, mediante las metodologías establecidas en la sección 3.5 se procedió a un etiquetado manual del conjunto de las muestras que cumplieran con los criterios establecidos por ambas metodologías y se realiza una comparación contrastada de los resultados obtenidos.

En la Tabla 10, se muestran el porcentaje de anomalías detectadas por cada metodología y para cada conjunto de datos experimentales en el conjunto de prueba. Como se observa en los resultados el modelo que detecto de forma más estable las anomalías fue el obtenido mediante el conjunto del dominio temporal, pues la variación del porcentaje de detección entre el método 1 y el 2 es solamente de un 0.61 %, mientras que en los otros conjuntos se evidencia una variación mucho mayor, siendo la variación más crítica la del conjunto de datos solamente con pre-procesamiento, con una variación de 6.02 %.

Tabla 10. Porcentaje de anomalías detectadas.

		Pre- Procesamiento	Dominio Temporal	Frecuencia	Tiempo/Frecuencia
Método 1	Leves	15.04 %	11.14 %	17.75 %	14.60 %
	Serias	8.07 %	3.38 %	6.19 %	4.77 %
	Graves	6.63 %	1.67 %	1.73 %	1.38 %
Método 2	Graves	0.61 %	1.06 %	0.16 %	0.03 %

Para realizar la evaluación de nuestro modelo en la detección de anomalías se seleccionó un intervalo de tiempo de siete días, comprendidos entre el 7-02-2020 al 13-02-2020, se procedió a realizar el etiquetado manual de las muestras que según el criterio de experto se consideran anomalías, y se aplicaron los métodos descritos anteriormente obteniendo los resultados mostrados en la Tabla 11. Para la evaluación del método 1 se seleccionaron todas las anomalías.

Tabla 11. Características del intervalo seleccionado.

		Intervalo 7-02 al 13-02
Total de muestras		840
Anomalías detectadas mediante la aplicación del método 1	Pre-procesamiento	380
	Dominio Temporal	102
	Frecuencia	425
	Tiempo/Frecuencia	225
Anomalías detectadas mediante la aplicación del método 2	Pre-procesamiento	45
	Dominio Temporal	61
	Frecuencia	0
	Tiempo/Frecuencia	0
Anomalías etiquetadas manualmente		26

A continuación, se muestran los resultados de las métricas de evaluación precisión, recall, AUC; para evaluar de la eficacia de nuestro modelo, así como de los métodos propuestos de detección en los diferentes conjuntos de datos experimentales. En la Tabla 12 se muestran los resultados para el método 1.

Como se observa el modelo obtenido mediante la aplicación de solamente técnicas de pre-procesamiento obtiene los mejores resultados. Esto es debido a que la aplicación de técnicas de suavizado, aunque mejoran la respuesta del modelo en función de la pérdida y el error de reconstrucción; lo hacen más sensible a la presencia de variaciones en las señales que no son anomalías como por ejemplo la influencia de condiciones climáticas (oscilaciones provocadas por nubes que pasan etc.).

Tabla 12. Resultados para el Método 1.

	Pre-Procesamiento	Dominio Temporal	Frecuencia	Tiempo/Frecuencia
precision	0.38	0.19	0.04	0.08
recall	0.83	0.76	0.73	0.69
AUC	0.89	0.83	0.63	0.72

En la Tabla 13 se muestran los resultados para el método 2. Como se observa en los conjuntos obtenidos mediante el procesamiento en el dominio de la frecuencia y la combinación de técnicas del dominio temporal con la frecuencia no son capaces de detectar ninguna anomalía en cambio. En cambio, el modelo obtenido mediante el conjunto con solamente el pre-procesamiento obtiene mejores resultados ya que discrimina mejor las falsas anomalías, como las variaciones provocadas por el clima, detectando casi todas las anomalías etiquetadas manualmente. Esto nos demuestra que el modelo es capaz de aprender las relaciones existentes entre el conjunto de señales sin necesidad de realizar técnicas de suavizado de la señal para eliminar la presencia de ruido.

Tabla 13. Resultados para el Método 2.

	Pre-Procesamiento	Dominio Temporal	Frecuencia	Tiempo/Frecuencia
Precision	0.53	0.39	-	-
Recall	0.92	0.92	-	-
AUC	0.97	0.93	-	-

A continuación, se muestra como ejemplo en la Fig 23 la señal de potencia de corriente alterna Pac en el intervalo de tiempo escogido, con las anomalías detectadas por el método 1, mediante el modelo obtenido con las técnicas de pre-procesamiento.

Como se observa el sistema detecta correctamente los comportamientos anómalos ocurridos el primer y tercer día del intervalo, pero es susceptible a las oscilaciones provocadas por el clima.




Fig. 23 Anomalías en señal Pac detectadas por el método 1.

En la Fig. 24 se muestra la misma señal, del mismo conjunto, con las anomalías detectadas por el método 2. Como se observa el sistema presenta una respuesta más robusta frente a las oscilaciones producidas por el clima.




Fig. 24 Anomalías en señal Pac detectadas por el método 2.

5. CONCLUSIONES Y TRABAJO FUTURO

En el presente trabajo se desarrolló un procedimiento para, a través del análisis de Series Temporales y mediante la aplicación de técnicas de Aprendizaje Profundo, obtener el Gemelo Digital de un sistema y utilizar el mismo para la detección de anomalías. Para la solución del objetivo se realizó primeramente un pre-procesamiento y análisis de características, realizando un estudio de su influencia en las señales estudiadas, y posteriormente analizar su influjo en la tarea planteada.

Para la obtención del Gemelo Digital se utilizó un enfoque basado en aprendizaje profundo utilizando autoencoders, donde mediante la combinación de capas convolucionales y LSTM, así como la influencia de diferentes parámetros se logra el objetivo de obtener el Gemelo Digital con un error de reconstrucción cercano a 0.1.

Posteriormente se realizaron varios experimentos para determinar la influencia del pre-procesamiento de las señales tanto en la obtención del Gemelo Digital como en la posterior detección de anomalías. Se observó que la aplicación de técnicas de procesamiento, tanto en el dominio de la frecuencia como del tiempo, logran mejorar la respuesta del modelo disminuyendo la función de pérdida y el error de reconstrucción. Pero la aplicación de estas técnicas presenta dos efectos en dependencia del método utilizado para la detección de anomalías; uno, provocando que el modelo sea más susceptible a oscilaciones no anómalas en las señales; dos, el modelo no detecta ninguna anomalía.

Teniendo en cuenta estos resultados se plantean varias ideas para realizar a trabajo futuro, como se describe a continuación:

- El desarrollo del modelo tanto como toda la experimentación del presente trabajo fue realizado sobre un conjunto de datos obtenidos de forma manual, en un periodo de tiempo determinado, por lo que se propone la implementación de un registro diario en el SCADA de los PSFV de estas variables.
- La conexión del Gemelo Digital a su Sistema Físico permite la posibilidad de establecer una ventana temporal al modelo la cual permitirá una continua alimentación de datos con el objetivo de un diagnóstico en línea, así como una retroalimentación que permita no solamente la continua mejora del modelo propuesto, sino también establecer una retroalimentación mediante alertas al personal de operación en casa de anomalías antes de que estas se puedan convertir en una falla potencial. Por esto se propone la puesta en producción del modelo propuesto en este trabajo.

- Unos de los inconvenientes de este estudio fue no contar con las variables meteorológicas, las cuales aportan información vital para el análisis y mejor comprensión de las relaciones temporales que se establecen entre las diferentes señales. Por lo tanto, se propone desarrollar métodos que permitan la integración de estas variables junto con las propias del sistema.

Referencias

- [1] International Energy Agency (2020), «Solar PV reports, IEA, Paris, 2020». [En línea]. Available: <https://www.iea.org/reports/solar-pv>.
- [2] R. J. Hyndman y G. Athanasopoulos, *Forecasting: principles and practice*, 2013.
- [3] A. Blázquez-García, A. Conde, U. Mori y J. A. Lozano, «A review on outlier/anomaly detection in time series data,» *arXiv preprint arXiv:2002.04236*, 2020.
- [4] D. Bacciu, «Unsupervised feature selection for sensor time-series in pervasive computing applications,» *Neural Computing and Applications*, vol. 27, nº 5, pp. 1077-1091, 2016.
- [5] C. Herff y D. J. Krusienski, «Extracting Features from Time Series,» *Fundamentals of Clinical Data Science*. Springer, Cham. pp. 85-100, 2019.
- [6] NIST/SEMATECH, «e-Handbook of Statistical Methods,» NIST/SEMATECH, [En línea]. Available: <https://www.itl.nist.gov/div898/handbook/pmcl/>.
- [7] R. H. Shumway y D. S. Stoffer, *Time series analysis and its applications*, 2000.
- [8] O. Brandes, J. Farley, M. Hinich y U. Zackrisson, «The Time Domain and the Frequency Domain in Time Series Analysis,» *The Swedish Journal of Economics*, vol. 70, nº 1, p. 25, 1968.
- [9] W. M. Laghari, M. U. Baloch, M. A. Mengal y S. J. Shah, «Performance Analysis of Analog Butterworth Low Pass Filter as Compared to Chebyshev Type-I Filter, Chebyshev Type-II Filter and Elliptical Filter,» *Circuits and Systems*, vol. 2014, nº 9, pp. 209-216, 2014.
- [10] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*, 2016.
- [11] K. O'Shea y R. Nash, «An Introduction to Convolutional Neural Networks,» *arXiv preprint arXiv:1511.08458*, 2015.

- [12] S. Hochreiter y J. Schmidhuber, «Long short-term memory,» *Neural Computation*, vol. 9, n° 8, pp. 1735-1780, 1997.
- [13] Y. Bengio, *Learning Deep Architectures for AI*, 2009.
- [14] A. Amidi, S. Amidi, «Stanford University,» 2020. [En línea]. Available: <https://stanford.edu/~shervine/teaching/cs-230/>.
- [15] Z. Che, S. Purushotham, K. Cho, D. A. Sontag y Y. Liu, «Recurrent Neural Networks for Multivariate Time Series with Missing Values.,» *Scientific Reports*, vol. 8, n° 1, pp. 6085-6085, 2018.
- [16] J. Jordan, «Introduccion to autoencoders» [En línea]. Available: <https://www.jeremyjordan.me/autoencoders/>.
- [17] P. Baldi, «Autoencoders, Unsupervised Learning, and Deep Architectures,» *Proceedings of ICML Workshop on Unsupervised and Transfer Learning*. vol. 27, pp. 37-50, 2012.
- [18] M. Grieves y J. Vickers, «Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems.» *Transdisciplinary perspectives on complex systems*. Springer, Cham. pp. 85-113, 2017.
- [19] A. Fuller, Z. Fan, C. Day y C. Barlow, «Digital Twin: Enabling Technologies, Challenges and Open Research,» *IEEE Access*, vol. 8, pp. 108952-108971, 2020.
- [20] B. R. Barricelli, E. Casiraghi y D. Fogli, «A survey on digital twin : definitions, characteristics, applications, and design Implications,» *IEEE Access*, vol. 7, pp. 167653-167671, 2019.
- [21] D. Hartmann y H. v. d. Auweraer, «Digital Twins.,» *arXiv: Computers and Society*, 2020.
- [22] W. Booyse, D. N. Wilke y S. Heyns, «Deep digital twins for detection, diagnostics and prognostics,» *Mechanical Systems and Signal Processing*, vol. 140, p. 106612, 2020.

- [23] A. Castellani, S. Schmitt y S. Squartini, «Real-World Anomaly Detection by using Digital Twin Systems and Weakly-Supervised Learning,» *IEEE Transactions on Industrial Informatics*, pp. 1-1, 2020.
- [24] R. Chalapathy y S. Chawla, «Deep Learning for Anomaly Detection: A Survey,» *arXiv preprint arXiv:1901.03407*, 2019.
- [25] V. Chandola, A. Banerjee y V. Kumar, «Anomaly detection: A survey,» *ACM Computing Surveys*, vol. 41, nº 3, p. 15, 2009.
- [26] P. K. Chan, M. V. Mahoney y M. H. Arshad, «A Machine Learning Approach to Anomaly Detection,» Tech. rep. CS-2003-06, Department of Computer Science, Florida Institute of Technology Melbourne, 2003.
- [27] W. Xiao, *Photovoltaic power system : modelling, design and control*, 2017.
- [28] Q. Qi y F. Tao, «Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison,» *IEEE Access*, vol. 6, pp. 3585-3593, 2018.
- [29] P. Malhotra, A. Ramakrishnan, G. Anand, L. Vig, P. Agarwal y G. M. Shroff, «LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection,» *arXiv preprint arXiv:1607.00148*, 2016.
- [30] M. Mohammadi, A. Al-Fuqaha, S. Sorour y M. Guizani, «Deep Learning for IoT Big Data and Streaming Analytics: A Survey,» *IEEE Communications Surveys and Tutorials*, vol. 20, nº 4, pp. 2923-2960, 2018.
- [31] J. Schmidhuber, «Deep learning in neural networks,» *Neural Networks*, vol. 61, pp. 85-117, 2015.
- [32] F. Karim, S. Majumdar, H. Darabi y S. Chen, «LSTM Fully Convolutional Networks for Time Series Classification,» *IEEE Access*, vol. 6, pp. 1662-1669, 2018.
- [33] P. Park, P. D. Marco, H. Shin y J. Bang, «Fault Detection and Diagnosis Using Combined Autoencoder and Long Short-Term Memory Network.,» *Sensors*, vol. 19, nº 21, p. 4612, 2019.

- [34] M. Schluse, M. Priggemeyer, L. Atorf y J. Rossmann, «Experimentable Digital Twins—Streamlining Simulation-Based Systems Engineering for Industry 4.0,» *IEEE Transactions on Industrial Informatics*, vol. 14, nº 4, pp. 1722-1731, 2018.
- [35] H. Cheng, P.-N. Tan, C. Potter y S. A. Klooster, «Detection and characterization of anomalies in multivariate time series,» de *9th SIAM International Conference on Data Mining 2009, SDM 2009*, 2009.
- [36] P. Jain, J. Poon, J. P. Singh, C. Spanos, S. R. Sanders y S. K. Panda, «A Digital Twin Approach for Fault Diagnosis in Distributed Photovoltaic Systems,» *IEEE Transactions on Power Electronics*, vol. 35, nº 1, pp. 940-956, 2020.
- [37] C. Zhang, D. Song, Y. Chen, X. Feng, C. Lumezanu, W. Cheng, J. Ni, B. Zong, H. Chen y N. V. Chawla, «A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data,» *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, nº 1, pp. 1409-1416, 2019.
- [38] S. Lin, R. Clark, R. Birke, S. Schonborn, N. Trigoni y S. Roberts, «Anomaly Detection for Time Series Using VAE-LSTM Hybrid Model,» de *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020.
- [39] C. Yin, S. Zhang, J. Wang y N. N. Xiong, «Anomaly Detection Based on Convolutional Recurrent Autoencoder for IoT Time Series,» *IEEE Transactions on Systems, Man, and Cybernetics*, pp. 1-11, 2020.
- [40] C. Zhou y R. C. Paffenroth, «Anomaly Detection with Robust Deep Autoencoders,» de *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2017.