



MODELO DE SERIE TEMPORAL PARA PRONOSTICAR LA TEMPERATURA SUPERFICIAL DEL MAR EN LA ZONA COSTERA DE PAITA (PERÚ)

Time series model to forecast the surface temperature of the sea in the coastal area of Paita (Perú)

OSCAR J. M. PEÑA CÁCERES¹, MANUEL A. MORE MORE¹, RUDY ESPINOZA NIMA¹, HENRY SILVA MARCHAN²

¹ Universidad Nacional de Piura, Perú

² Universidad Nacional de Tumbes, Perú

KEYWORDS

*El Niño Phenomenon
Sea Surface Temperature
Time series
Artificial Neural Network
Population*

ABSTRACT

Artificial intelligence techniques have evolved and strengthened, allowing the development of transversal proposals that watch over and safeguard the integrity of the human being. The objective of this study is to develop a time series that forecasts the Sea Surface Temperature (SST) on an average daily scale in the coastal area of Paita, Perú. The methodology used focused on five phases, from data collection to model validation. The results obtained reveal that there is a margin of error of 3.96% on the SST on a weekly average scale and a difference of 0.05 to 1.42, on a daily basis.

PALABRAS CLAVE

*Fenómeno El Niño
Temperatura Superficial del Mar
Serie de Tiempo
Red Neuronal Artificial
Población*

RESUMEN

Las técnicas de inteligencia artificial han evolucionado y fortalecido permitiendo desarrollar propuestas transversales que velen y salvaguarden la integridad del ser humano. El presente estudio tiene como objetivo, elaborar una serie de tiempo que pronostique la Temperatura Superficial del Mar (TSM) a escala promedio diaria en la zona costera de Paita, Perú. La metodología empleada se centró en cinco fases, desde la recolección de datos hasta la validación del modelo. Los resultados obtenidos dan a conocer que existe un margen de error del 3.96% sobre la TSM a escala promedio semanal y una diferencia de 0.05 a 1.42, de manera diaria.

Recibido: 09/ 05 / 2022

Aceptado: 20/ 07 / 2022

1. Introducción

El mundo y los efectos del cambio climático al siglo XXI, se han convertido en uno de los temas más abordado por la comunidad científica. Esto debido a la variabilidad de factores climáticos y oceanográficos que impactan en la presencia de eventos adversos y que generan un sin número de daños y pérdidas humanas.

El Fenómeno El Niño (FEN) también es conocido como uno de los eventos climáticos irregulares por su inestabilidad en el océano y la atmósfera. Su influencia se ve reflejada en patrones anormales sobre el comportamiento de corrientes oceánicas, flujos de viento, precipitaciones pluviales y la Temperatura Superficial del Mar (TSM). Este Fenómeno ha empezado a estudiarse con mayor frecuencia, a tal punto de comprender como se forma y se mantiene durante los meses de verano en la costa norte del Perú. El calentamiento de la TSM durante los meses de diciembre, enero y febrero entre Perú y Ecuador es sólo una aproximación que simboliza a este fenómeno (Condori, 2020).

En este contexto el Fenómeno El Niño es un evento de característica océano-atmosférico cuya presencia se debe al incremento de la TSM y el desplazamiento de grandes volúmenes de aguas cálidas del pacífico occidental hacia el pacífico ecuatorial. Uno de los patrones de referencia para la aparición de este evento es el incremento de la TSM y que su promedio se encuentre entre 0,5 °C, o más, por al menos durante 3 meses consecutivos (Hijar et al., 2016).

El último evento se produjo en el año 2017, cuando fue catalogado como Fenómeno El Niño Costero, por el rápido calentamiento de la Temperatura Superficial del Mar (TSM) en la zona costera de Paita, llegando a generar fuertes precipitaciones pluviales que produjeron el desborde del río Piura.

En el litoral costero peruano existen 12 estaciones oceanográficas que son administradas por el Instituto del Mar Peruano (IMARPE), encargados de realizar la toma de datos sobre la TSM a escala diaria durante todo el año. Este insumo es una de las variables oceanográficas que contribuye al desarrollo de estudios sobre el FEN y sobre todo a efectuar un monitoreo permanente sobre su comportamiento. Este tipo de acciones que se realizan de forma continua bajo un escenario libre de riesgos y sin exposiciones que afecten la integridad de profesionales dedicados a esta labor. La COVID-19, desencadenó cambios disruptivos y estimuló el desarrollo de visiones transversales que promuevan la generación de conocimiento y el ser humano puede proponer soluciones no solo para afrontar la COVID-19, sino dinamizar nuevos métodos y técnicas colaborativas que aseguren la continuidad de los procedimientos en una organización (Cáceres et al., 2022).

Es necesario mencionar que las técnicas computacionales han demostrado tener capacidad para desarrollar propuestas disruptivas que contribuyan a dinamizar acciones y a establecer nuevos enfoques en beneficio de la población y sobre todo a apoyar la adopción de decisiones de las autoridades de turno.

El objetivo de este estudio fue diseñar un modelo de serie de tiempo mediante el empleo de Redes Neuronales Artificiales (RNA) que pronostique la TSM a escala diario-semanal en la zona costera de Paita (Perú) y contribuya a establecer una mejor previsión sobre el comportamiento de la TSM y fortalezca la toma de decisiones de las autoridades locales, cuando existen limitaciones en el registro de datos oceanográficos.

2. Trabajos relacionados

El estudio de (Wu et al., 2006) where sea level pressure and SST anomalies were used as predictors to predict the five leading SST principal components at lead times from 3 to 15 months. Relative to the linear regression (LR), pronósticos de las temperaturas de la superficie del mar del Pacífico tropical mediante redes neuronales, da a conocer que es posible disponer de resultados confiables si, se utiliza una red neuronal de perceptrones de múltiples capas, donde la presión a nivel del mar y las anomalías de la temperatura del mar se consideran como predictores.

Los principales resultados de la investigación, Pronóstico de la temperatura de la superficie del mar (TSM) en el Atlántico tropical con el uso de redes neuronales artificiales, por (Castro et al., 2020), señalan que es posible aplicar Redes Neuronales Artificiales para predecir la temperatura superficial del mar en el Océano Atlántico Tropical y el Gradiente Meridional de anomalías de temperatura superficial del mar en el Atlántico Tropical. Además de disponer correlaciones, significativas al 95% y óptimos resultados cuando se usa el TSM promedio de forma trimestral.

(Wolff et al., 2020), en su investigación, modelado de conjuntos estadísticos y de aprendizaje automático para pronosticar la temperatura de la superficie del mar, indica que viable la determinación de este aplicando técnicas de aprendizaje automático con enfoques de regresión, árboles de decisión y aprendizaje profundo, para estimar las temperaturas de la superficie del mar (TSM), además de considerar el bajo costo computacional de la inferencia hace que el enfoque sea particularmente atractivo para la computación basada en el borde donde los modelos predictivos podrían implementarse en dispositivos de baja potencia en el entorno marino.

Para (Bellagarda et al., 2022), las Tecnologías de la Información y Comunicaciones brindan oportunidades innovadoras para que la previsión e integración de nuevas políticas de control, sin embargo, dichas tecnologías deben superar desafíos como la falta de datos históricos precisos necesarios para las predicciones. La aplicabilidad de redes neuronales innovadoras para predicciones de series temporales, han permitido con efectividad establecer

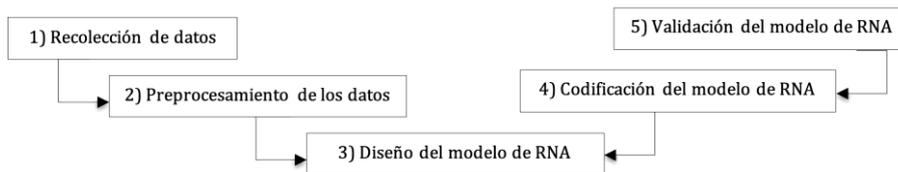
un pronóstico de la temperatura del aire interior, mostrando niveles constantes de precisión y comodidad. Investigaciones como la de (Choi et al., 2021), expresan un enfoque probabilístico para pronosticar la temperatura a corto plazo y sea útil como una alternativa frente a escenarios cambiantes basado en riesgos y no se pierda la continuidad de los datos.

Los estudios antes mencionados permiten observar con mayor certeza y precisión los avances que la comunidad científica ha venido impartiendo, dando lugar al empleo de técnicas de inteligencia artificial mediante la aplicación de redes neuronales artificiales y enfoques probabilísticos que permitan dar a conocer a un futuro el comportamiento de la TSM y disponer de datos históricos para la continuidad de investigaciones que coadyuven a la generación de nuevas propuestas.

3. Metodología

La metodología empleada se centró en 5 fases, tal como se observa en la Figura 1.

Figura 1. Metodología



Fuente(s): Elaboración Propia, 2022.

3.1. Recolección de datos

Para el desarrollo de una serie de tiempo se requiere de datos históricos de por lo menos 10 años de manera continua y sobre todo confiables. En merito a ello, se recurrió al Instituto del Mar Peruano – IMARPE una de las instituciones técnico científicas del Perú, dedicada a brindar asesoría científica, veraz y oportuna para el aprovechamiento sostenible de los recursos vivos del mar y las aguas continentales. La Figura 2, representa la ubicación de la oficina desconcentrada de IMARPE en Paita.

Figura 2. Ubicación IMARPE y su ámbito geográfico en Paita.



Fuente: IMARPE, 2013

IMARPE, proporcionó 14,669 índices de registro a escala diaria sobre la temperatura superficial del mar. Los datos de la Tabla 1, representan una secuencialidad desde el año 1982 al 2021 y fueron tomados en la estación oceanográfica ubicada en Paita. Frente a ello es importante mencionar que las predicciones de la temperatura superficial del mar se basan principalmente en modelos numéricos y estadísticos (Astsatryan et al., 2021) a vital climatic parameter, the temperature has a direct impact on evaporation, frost, and snow melting. Temperature predictions are based mainly on numerical and statistical models. Sometimes it is a challenge to improve the weather forecast accuracy. The article aims to implement a weather prediction technique based on machine learning methods and approaches to improve the hourly air temperature prediction for up to 24 hours in the Ararat valley (Armenia).

Tabla 1. Datos TSM

	TSM	Día	Mes	Año
...
102	20.30	12	04	1982
103	19.23	13	04	1982
104	18.97	14	04	1982
...
14669	26.53	14	03	2022

Fuente(s): IMARPE, 2022.

3.2. Preprocesamiento de datos

Partió por analizar y evaluar la integridad de 14669 datos de temperatura superficial del mar, entre los datos encontrados se pudo observar valores faltantes que en muchos de los casos correspondían a días feriados o fines de semana. Esto debido a que los profesionales de las entidades técnico científicas no realizan labores en estas fechas, dejando vacíos y sin informar a las autoridades de turno. Además de ello, durante los años 2019 y 2020, la COVID-19, tuvo un impacto bastante negativo que afectó la integridad física y psicológica de la gran mayoría de colaboradores y sobre todo dejando pérdidas humanas que desenvolvían un papel clave dentro de las instituciones técnico científicas y que se vio reflejado en la inestabilidad de toma de datos de temperatura superficial del mar por la inactividad de tareas presenciales que hoy en día requiere de nuevos mecanismos y propuestas enmarcadas en proyecciones o estimaciones.

En merito a lo antes expresado se hizo empleo del lenguaje de programación Python, por su facilidad para la programación orientada a objetos, imperativa y funcional. En los últimos años ha ido ganando adeptos en comunidades como la de software libre, científica y educacional, por su sencillez y posibilidad de concentrarse en los problemas actuales (Holguín et al., 2014) que muchas veces requieren de un amplio conocimiento para brindar una solución, sin embargo, a través de Python fue posible aplicar instrucciones para reemplazar los datos que se encontraban en una condición NaN, tal como se observa en la Tabla 2.

Tabla 2. Datos faltantes de la TSM

	TSM	Día	Mes	Año
...
100	21.53	10	04	1982
101	NaN	11	04	1982
102	20.30	12	04	1982
...
14669	26.53	14	03	2022

Fuente(s): IMARPE, 2022.

El modo de reemplazar los datos de la Tabla 2, estuvo sujeto en el mapeo de fechas más cercanas a los valores NaN y el dato sea reemplazado por el que indica el día anterior o próximo, llegando a tener resultados como los que se observa en la Tabla 3 y permiten la continuidad del presente estudio.

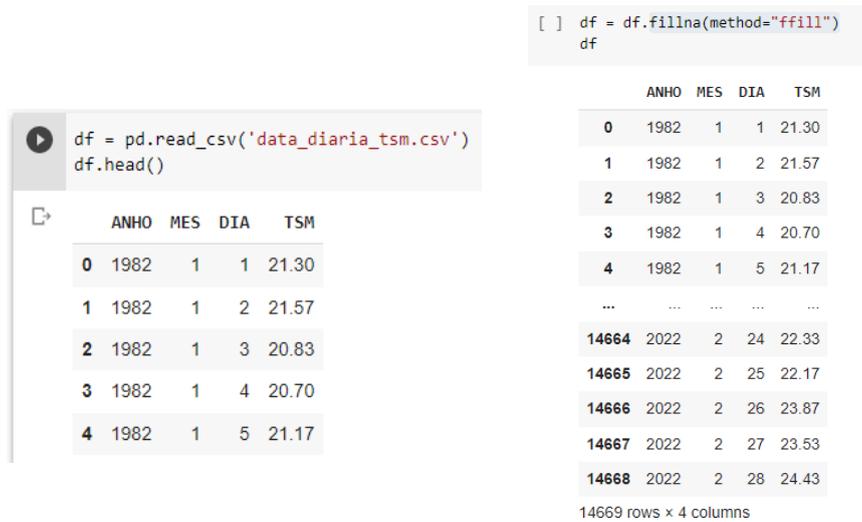
Tabla 3. Datos de TSM preprocesados

	TSM	Día	Mes	Año
...
100	21.53	10	04	1982
101	21.53	11	04	1982
102	20.30	12	04	1982
...
14669	26.53	14	03	2022

Fuente(s): IMARPE, 2022.

Es importante mencionar que, para el desarrollo de esta labor, se empleó la plataforma de Google Colab, donde se hizo empleo de las instrucciones que se visualizan en la Figura 3.

Figura 3. Instrucciones de reemplazamiento de datos de TSM



Fuente(s): Elaboración Propia, 2022.

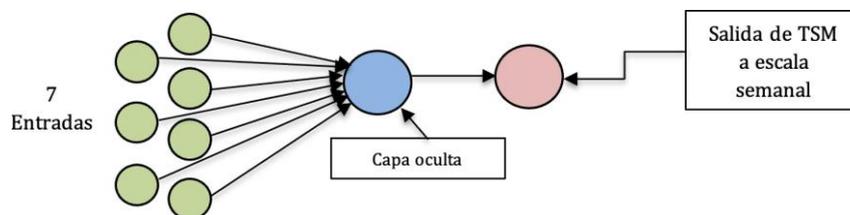
3.3. Diseño del modelo de RNA

Una RNA, se enmarca por ser un algoritmo inspirado en el comportamiento de neuronas biológicas mediante las cuales exploran información y se encuentran articulados por nodos o neuronas interconectadas entre sí. La principal característica de este algoritmo es su capacidad para aprender.

Para disponer de una serie temporal, es necesario conocer que descompone por un conjunto de muestras tomadas a intervalos de tiempo regulares, que pueden estar fraccionados entre 5 a 10 años como mínimo. Por otro lado, disponer de datos en espacios de tiempo más extensos podría brindarnos resultados más certeros. Es interesante estudiar el comportamiento de una serie temporal a mediano y largo plazo, esto por qué permite identificar patrones que sean considerados para el desarrollo de nuevos pronósticos y estudios en el futuro.

En muchos de los casos se cree que trabajar con series de tiempo es utilizar criterios de regresión lineal, sin embargo, las series de tiempo enfocadas en RNA representan una característica más transversal debido a que tienen mayor performance en contextos de muchos datos, mientras más grande sea la arquitectura de la red neuronal también obtiene mayor performance en cuanto se agregan más datos (Alonzo et al., 2021) y para este caso la Figura 3, representa el modelo de RNA.

Figura 3. Diseño del modelo de RNA Backpropagation



Fuente(s): Elaboración Propia, 2022.

3.4. Codificación del modelo de RNA

Para la codificación del modelo de RNA que pronostique la temperatura superficial del mar a escala diaria en fragmentos semanales se ha requerido de emplear técnicas de programación enfocadas en el lenguaje de programación Python, teniendo en consideración que su principal característica se basa en la resolución de problemas de optimización y técnicas de propagación. Python es gratuito y de código abierto. Para centrarse en

resolver problemas de optimización y evitar problemas de instalación, él se hace empleo de la plataforma Google Colab, que permite escribir código Python desde cualquier navegador web (Kuroki, 2021).

Después de haber abordado la fase de preprocesamiento de datos y el modelo de RNA, se identificaron librerías que permitirán el procesamiento, integridad y lectura de los datos que se encuentran en formato CSV, tal como se visualizan en la Figura 4.

Figura 4. Librerías utilizadas para el pronóstico de serie de tiempo

```
[ ] import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
%matplotlib inline
plt.rcParams['figure.figsize'] = (16, 9)
plt.style.use('fast')

from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten
from sklearn.preprocessing import MinMaxScaler
```

Fuente(s): Elaboración Propia, 2022.

Es importante que la librería panda, permite realizar lectura y verificación del origen de datos. La Figura 5, representa las acciones que se realizaron para cargar los datos, describirlos y posteriormente formatear el valor de la columna fecha, debido que esta mantenía un formato diferente.

Figura 5. Librerías utilizadas para el pronóstico de serie de tiempo

Instrucción 1

```
[ ] df = pd.read_csv('data_diaria_tsm_up.csv')
df.head()
```

	Fecha	TSM
0	1/01/1982	21.30
1	2/01/1982	21.57
2	3/01/1982	20.83
3	4/01/1982	20.70
4	5/01/1982	21.17

Instrucción 2

```
df.describe()
```

	TSM
count	14669.000000
mean	19.232475
std	3.053432
min	14.300000
25%	16.830000
50%	18.500000
75%	20.970000
max	30.500000

Instrucción 3

```
[ ] df['Fecha'] = pd.to_datetime(df['Fecha'])
df.set_index('Fecha',inplace=True,)
df.head()
```

	Fecha	TSM
	1982-01-01	21.30
	1982-02-01	21.57
	1982-03-01	20.83
	1982-04-01	20.70
	1982-05-01	21.17

Fuente(s): Elaboración Propia, 2022.

Después de verificar la integridad de los datos importados, se procedió a tomar en consideración que, en los últimos 40 años, la presencia del Fenómeno El Niño en la Región Piura, estuvo sujeto al comportamiento dinámico de la temperatura superficial del mar en los años 1983, 1997, 1998 y 2017. La variabilidad de la temperatura superficial durante en el tiempo antes indicados son uno de los patrones de referencia que reflejan una estacionalidad significativa.

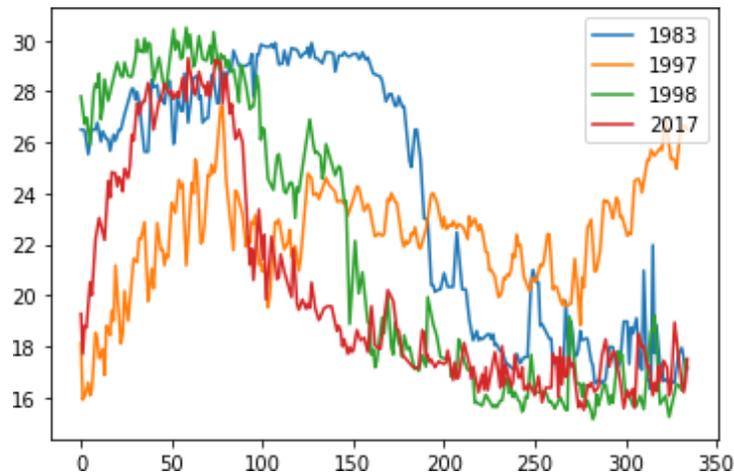
Es por ello, que gracias a las instrucciones empleadas en la Figura 5, ha sido posible observar el comportamiento de la temperatura superficial del mar, tal como lo expresa la Figura 6 y mediante el cual es posible darse cuenta que durante los meses de febrero, marzo y abril, existe un cambio en el índice de esta variable oceanográfica.

Figura 5. Instrucción para conocer la variabilidad de la TSM

```
[ ] verano1983 = df['1983-01-01':'1983-12-01']
plt.plot(verano1983.values,label='1983')
```

Fuente(s): Elaboración Propia, 2022.

Figura 6. Comportamiento de la TSM en los años más resaltantes



Fuente(s): Elaboración Propia, 2022.

Después de conocer el comportamiento estacional de la variable antes indicada, se procedió a alterar el flujo de entrada del origen de datos que se encuentra en formato CSV y que contiene los datos de la TSM de forma secuencial. Esta se fragmentará en 8 columnas donde 7 de ellas corresponden a las entradas y la última a la salida. La Figura 7, ilustra los datos de la temperatura superficial del mar que han sido transformados en valores de -1 y 1, teniendo en cuenta que este tipo de escalados uniformiza y favorece el desenvolvimiento de la RNA para realizar cálculos.

Finalmente, la serie de tiempo se convierte en un problema de tipo supervisado con un enfoque backpropagation.

Figura 7. Entradas y salida transformadas en rango de -1 y 1

	var1(t-7)	var1(t-6)	var1(t-5)	var1(t-4)	var1(t-3)	var1(t-2)	var1(t-1)	var1(t)
7	-0.135803	-0.102469	-0.193827	-0.209876	-0.151852	-0.053087	-0.008642	0.070370
8	-0.102469	-0.193827	-0.209876	-0.151852	-0.053087	-0.008642	0.070370	-0.185185
9	-0.193827	-0.209876	-0.151852	-0.053087	-0.008642	0.070370	-0.185185	-0.341975
10	-0.209876	-0.151852	-0.053087	-0.008642	0.070370	-0.185185	-0.341975	-0.370370
11	-0.151852	-0.053087	-0.008642	0.070370	-0.185185	-0.341975	-0.370370	-0.300000

Fuente(s): Elaboración Propia, 2022.

Habiendo realizado el escalado de datos, se hizo necesario subdividir el conjunto de datos en dos grupos, de entrenamiento y prueba. Por lo tanto, la subdivisión se enfocó en un 70% para valores de entrenamiento y un 30% de prueba. Esta es una proporción considerable debido que existe un robusto origen de datos y que por el momento puede ser la más óptima.

Teniendo en cuenta la arquitectura de la RNA, es importante mencionar que las 7 entradas que se indicaron anteriormente y la capa oculta con 7 neuronas pueden variar, sin embargo, función de activación que se emplea es la tangente hiperbólica puesto que se disponen valores entre -1 y 1.

Además de ello, se consideró como optimizador emplear, Adam, por ser un método realmente eficiente que cuando trabaja con un gran problema que involucra una gran cantidad de datos o parámetros, requiere menos memoria y es eficiente. Por otro lado, la métrica de pérdida es de error absoluto medio que calcula como la suma media de los valores absolutos de los errores identificados en el proceso de entrenamiento de la RNA.

Habiendo definido criterios de la arquitectura de la RNA, para llegar a la etapa de predicción se tuvo en cuenta hacer empleo de valores continuos y no discretos. Para calcular la precisión se hizo empleo del error cuadrático medio para saber si mejora el entrenamiento o se debería reducir el número de épocas, teniendo en cuenta que se ejecutara el algoritmo backpropagation. En cada ciclo de épocas todos los datos de entrenamiento pasan por la red neuronal para que esta aprenda sobre ellos, si existen 100 ciclos y 10000 datos, cada ciclo los 10000 datos pasaran por la red neuronal. Tal como se observa, la Figura 8, describe la arquitectura de la RNA y el número de épocas consideradas, que son 100 ciclos de aprendizaje.

Figura 8. Red Neuronal Artificial

```
[ ] def crear_modeloFF():
    model = Sequential()
    model.add(Dense(PASOS, input_shape=(1,PASOS),activation='tanh'))
    model.add(Flatten())
    model.add(Dense(1, activation='tanh'))
    model.compile(loss='mean_absolute_error',optimizer='Adam',metrics=["mse"], run_eagerly=True)
    model.summary()
    return model

[ ] EPOCHS=100

model = crear_modeloFF()

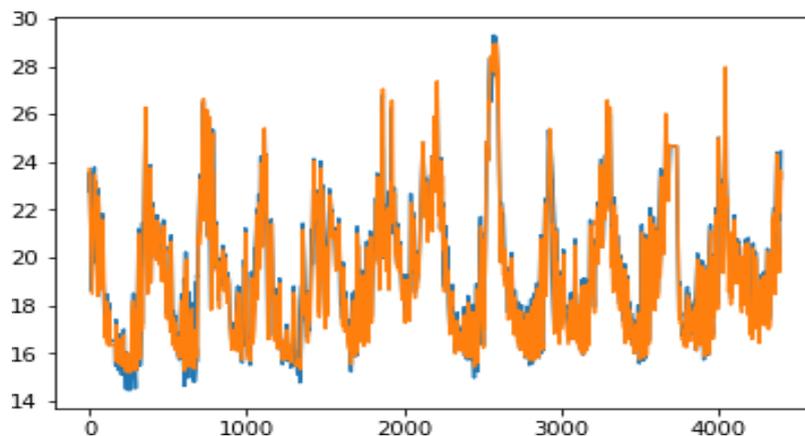
history=model.fit(x_train,y_train,epochs=EPOCHS,validation_data=(x_val,y_val),batch_size=PASOS)
```

Fuente(s): Elaboración Propia, 2022.

3.5. Validación del modelo de RNA

En este apartado se realizó la validación de los datos reales y pronosticados, cuya representación se muestra en Figura 9 y da a conocer como el desenvolvimiento de la serie de tiempo mediante el empleo de una RNA, tiende a ser muy certera y aproximada en sus resultados.

Figura 9. Validación de datos reales y pronosticados



Fuente(s): Elaboración Propia, 2022.

Por otro lado, fue necesario describir un resumen de los datos que se ilustran en la Figura 9 y conocer la diferencia que existe entre los valores reales y pronosticados en aras de establecer un margen de error sobre los 4393 datos que equivalen aproximadamente un 30% de los índices de registro utilizados para el entrenamiento, tal como se visualiza en la Figura 10.

Figura 10. Validación de datos reales, pronosticados y sus diferencias



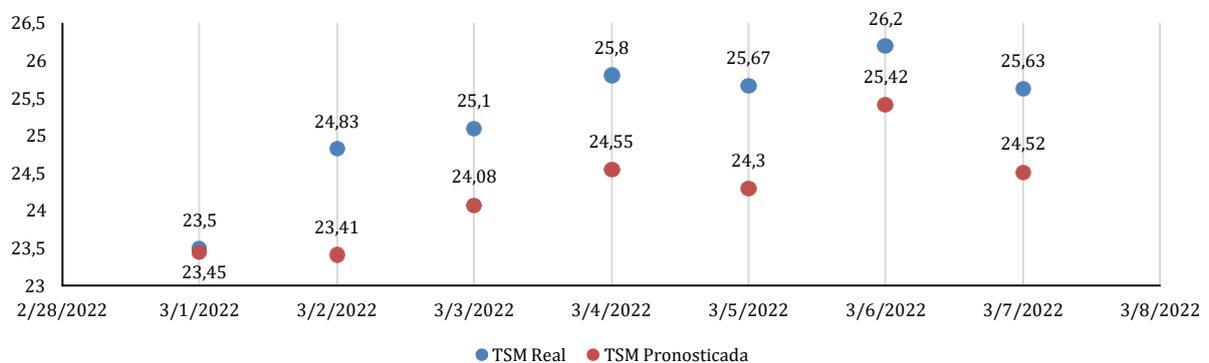
Fuente(s): Elaboración Propia, 2022.

La Figura 10, expresa dos reflejos, en el primero se puede apreciar la evaluación de los cinco primeros valores obtenidos cuyas diferencias van desde -0.12 a 1.16. En el segundo apartado se tiene un error medio de 0.016, sobre el promedio de los 4393 valores del conjunto de datos de prueba.

4. Resultados

El cambio climático y sus efectos demuestran que es de necesidad disponer de medios y herramientas que coadyuven al seguimiento y monitoreo de su comportamiento. En este estudio ha sido posible el desarrollo de una serie de tiempo, que pronostique la temperatura superficial del mar empleando redes neuronales artificiales, llegando a obtener resultados sólidos y confiables, tal como se visualiza en la Figura 11.

Figura 11. TSM real y pronosticada



Fuente(s): Elaboración Propia, 2022.

Es importante precisar que la Figura 11, representa TSM a escala promedio diario-semanal. En este primer acercamiento se buscó pronosticar la TSM en los próximos siete días después de finalizar el mes de febrero del año 2022. Los valores pronosticados expresan una aproximación bastante cercana de los valores reales, sin embargo, es necesario expresar que las diferencias son mínimas, pero no menos importantes por lo que aún puede mejorarse el modelo de serie temporal propuesto.

La diferencia que existe entre los valores de la Figura 11, son de 0.05 y 1.42. Este tipo de pronósticos son significativos, más aún cuando se dispone de márgenes de error mínimos que pueden ser empleados para el desarrollo de comunicados, informes técnicos y boletines prospectivos frente al comportamiento de la temperatura superficial del mar, cuando se tienen limitaciones de acceso por problemas del mundo.

En aras de tener una mejor visión sobre los resultados obtenidos, la Tabla 3, ilustra la variabilidad diaria que se encuentra entre el 1 y 7 de marzo del 2022. El promedio pronosticado a escala semanal es de 24.24, mientras que el valor real corresponde a 25.24, lo que significa que existe un margen de error de 3.96% a escala semanal.

Tabla 3. TSM pronosticada a escala promedio diario semanal

	Fecha	TSM	TSM Pronosticada	Diferencia
1	01-03-2022	23.50	23.45	0.05
2	02-03-2022	24.83	23.41	1.42
3	03-03-2022	25.10	24.08	1.02
4	04-03-2022	25.80	24.55	1.25
5	05-03-2022	25.67	24.30	1.37
6	06-03-2022	26.20	25.42	0.78
7	07-03-2022	25.63	24.52	1.11
Promedio semanal		25.24	24.24	1.00

Fuente(s): IMARPE, 2022.

Si bien es cierto las técnicas y métodos enmarcados en pronósticos son acercamientos para actuar frente a escenarios difíciles y emergentes, los resultados logrados demuestran que es posible disponer de soluciones confiables y seguras como medio alternativo para la continuidad de los servicios y particularmente cuando se deben adoptar decisiones que salvaguarde la integridad de la población y los medios de vida.

Es necesario no olvidar que la Región Piura es una de las pioneras en conocer la presencia del Fenómeno El Niño y que el seguimiento de este evento se desarrolla por la variabilidad de la TSM, siendo importante su aplicación para las entidades técnico científicas, académica, organizaciones privadas y población en general.

5. Conclusiones

La presencia de eventos adversos son uno de los motivos por los que la población y en lo particular, la comunidad científica debe empezar adoptar conciencia y a emprender en propuestas y medios alternativos que contribuyan al seguimiento y monitoreo de fenómenos, como lo es El Fenómeno El Niño en la Región Piura. Este evento a lo largo de los años ha brindado de diversos de recursos entre los más significativos, el recurso hídrico, por lo que debería considerarse una bendición para el ser humano, más no un problema, sin embargo, se ve de esta manera porque no se dispone de los medios esenciales para hacer frente a su impacto.

Es por ello, que los medios tecnológicos deben considerarse como uno de los eslabones principales para conocer más de cerca el comportamiento del Fenómeno El Niño. De esta forma, la aplicación de técnicas de inteligencia artificial, han permitido ejecutar ideas y pensamientos que muchas veces se quedan en espacios de coordinación.

El presente estudio da a conocer que existe una diferencia mínima que va de 0.05 a 1.42, sobre la temperatura superficial de la mar pronosticada y los valores reales que son obtenidos gracias al Instituto del Mar Peruano y que ha servido como insumo para validar el rendimiento de la serie de tiempo.

El margen de error a escala semanal sobre la temperatura superficial del mar es de 3.96%, porcentaje que se considera estar dentro de los estándares permitidos $\leq 5\%$.

La presencia de la COVID-19, no debe ser un obstáculo para la sociedad, más bien, convertirse en el impulso para el desarrollo de nuevas metodologías, estrategias y formas donde la continuidad de los servicios sea estable y permanente sin necesidad de mencionar expresiones como, la pandemia daño la secuencialidad de las tareas que realizan las instituciones técnico científicas.

Finalmente, la investigación ha cumplido con sus objetivos iniciales, sin embargo, se deben proyectar mejoras en base a los resultados obtenidos que aseguren la confiabilidad de los datos que genera la serie de tiempo y se prevea el desarrollo de un modelo mediante técnicas de inteligencia artificial que prediga el Fenómeno El Niño en la Región Piura, ya que se dispone de este primer insumo de acceso a la comunidad científica.

6. Agradecimientos

El presente estudio nace en el marco de la investigación predoctoral denominada, "Diseño de Un Modelo de Red Neuronal para la predicción del Fenómeno El Niño en la Región Piura", de la Universidad Nacional de Piura (UNP). Los datos de la Temperatura Superficial del Mar, fueron brindados por el Instituto del Mar Peruano (IMARPE).

Referencias

- Alonzo, R., Salguero, F., Javier, F., & Morales, A. (2021). Series Temporales Avanzadas: Aplicación de Redes Neuronales para el Pronóstico de Series de Tiempo. *Universidad de Granada*.
- Astsatryan, H., Grigoryan, H., Poghosyan, A., Abrahamyan, R., Asmaryan, S., Muradyan, V., Tepanosyan, G., Guigoz, Y., & Giuliani, G. (2021). Air temperature forecasting using artificial neural network for Ararat valley. *Earth Science Informatics 2021 14:2*, 14(2), 711-722. <https://doi.org/10.1007/S12145-021-00583-9>
- Bellagarda, A., Cesari, S., Aliberti, A., Ugliotti, F., Bottaccioli, L., Macii, E., & Patti, E. (2022). Effectiveness of neural networks and transfer learning for indoor air-temperature forecasting. *Automation in Construction*, 140, 104314. <https://doi.org/10.1016/J.AUTCON.2022.104314>
- Cáceres, O. J. M. P., More, M. A. M., Sojo, R. E. C., & Silupu, E. R. G. (2022). Social distancing in the face of COVID-19: simulation of the maximum capacity of people through PHP. *Ingenius*, 27(27), 9-16. <https://doi.org/10.17163/INGS.N27.2022.01>
- Castro, E. S., Alves, J. M. B., Da Silva, E. M., Campos, J. N., & Alves, A. O. (2020). Forecast of sea surface temperature (SST) in Tropical Atlantic with the use artificial neural networks. *Revista Brasileira de Meteorologia*, 35(3), 505-515. <https://doi.org/10.1590/0102-77863540075>
- Choi, B., Bergés, M., Bou-Zeid, E., & Pozzi, M. (2021). Short-term probabilistic forecasting of meso-scale near-surface urban temperature fields. *Environmental Modelling & Software*, 145, 105189. <https://doi.org/10.1016/J.ENVSOF.2021.105189>
- Condori, P. P. C. (2020). Derivados financieros y los efectos del fenómeno El Niño en la rentabilidad de las empresas pesqueras y agroindustriales peruanas. *Economía & Negocios*, 2(1), 15-23. <https://doi.org/10.33326/27086062.2020.1.904>
- Hijar, G., Bonilla, C., Munayco, C. V., Gutierrez, E. L., & Ramos, W. (2016). Fenómeno el niño y desastres naturales: intervenciones en salud pública para la preparación y respuesta. *Revista Peruana de Medicina Experimental y Salud Publica*, 33(2), 300-310. <https://doi.org/10.17843/RPMESP.2016.332.2205>
- Holguín, C., Díaz-Ricardo, Y., & Antonio Becerra-García, R. (2014). *El lenguaje de programación Python*. <http://www.linuxjournal.com/article/2959>
- Kuroki, M. (2021). Using Python and Google Colab to teach undergraduate microeconomic theory. *International Review of Economics Education*, 38, 100225. <https://doi.org/10.1016/J.IREE.2021.100225>
- Wolff, S., O'Donncha, F., & Chen, B. (2020). Statistical and machine learning ensemble modelling to forecast sea surface temperature. *Journal of Marine Systems*, 208, 103347. <https://doi.org/10.1016/J.JMARSYS.2020.103347>
- Wu, A., Hsieh, W. W., & Tang, B. (2006). Neural network forecasts of the tropical Pacific sea surface temperatures. *Neural Networks*, 19(2), 145-154. <https://doi.org/10.1016/J.NEUNET.2006.01.004>