

ARTÍCULO ORIGINAL



Herramienta informática para la medición y predicción del cambio de la línea de costa

Computer Tool for Measuring and Predicting Coastal Line Change



Leonardo Fundora Luis

leonardo.fundoraluis@outlook.com • <https://orcid.org/0000-0002-1902-8893>

Eduardo Javier Berrio Turiño

eduardo.berrio@umcc.cu • <https://orcid.org/0000-0002-8314-379X>

Liz Pérez Martínez

lizy.perez@umcc.cu • <https://orcid.org/0000-0001-6187-7875>

UNIVERSIDAD DE MATANZAS, CUBA

Recibido: 2023-04-02 • Aceptado: 2023-07-20

RESUMEN

La dinámica de la costa es un fenómeno complejo que requiere una monitorización continua para comprender mejor los procesos que están implicados y tomar decisiones adecuadas. La medición de la línea de costa es una tarea esencial en este proceso, ya que permite conocer la posición actual de la costa y su tendencia temporal. El enfoque de ciencia ciudadana es una solución prometedora y *CoastSnap* es una reciente creación en este campo. Sin embargo, para su operación, el código que permite el análisis de imágenes requiere la plataforma propietaria MATLAB. Esta barrera podría minimizarse mediante el uso de alternativas gratuitas a MATLAB, como *Python*. El objetivo de este trabajo es desarrollar una herramienta informática que posibilite la medición y predicción del cambio de la línea de costa, a partir de imágenes obtenidas de diversas fuentes. El producto resultante de la aplicación de la metodología expuesta en este trabajo demuestra, con datos de prueba, el valor de uso que tiene para la toma de decisiones informadas y así contribuir a mitigar los efectos de la variación de la extensión de la costa y proteger áreas vulnerables.

PALABRAS CLAVE: ambiental, ciencia ciudadana, línea de costa, monitorización; predicción.



ABSTRACT

The coast's dynamics is a complex phenomenon that requires continuous monitoring to better understand the processes involved and make appropriate decisions. Measuring the coastline is an essential task in this process, allowing us to know the current position of the coast and its temporal trend. The citizen science approach is a promising solution, and CoastSnap is a recent creation in this field. However, the code that allows image analysis requires the proprietary MATLAB platform for operation. This barrier could be minimized by using free alternatives to MATLAB, such as Python. The objective of this work is to develop a computer tool that enables the measurement and prediction of changes in the coastline from images obtained from various sources. The resulting product of the methodology exposed in this work demonstrates, with test data, the value of use it has for making informed decisions and thus contributing to mitigating the effects of changes in the extent of the coast and protecting vulnerable areas.

KEYWORDS: *citizen science, coastal line, environmental, monitoring, prediction.*

INTRODUCCIÓN

Las costas impactan en la vida humana, la biodiversidad, la economía y el ocio, y actúan como una barrera protectora entre las olas, los niveles de agua elevados y las comunidades costeras vulnerables (Harley, Kinsela, Sánchez-García y Vos, 2019).

Actualmente, el interés en el monitoreo costero se ha expandido desde grupos de investigación especializados a comunidades costeras en todo el mundo, debido a que el cambio climático ha alterado las condiciones que enfrentan las regiones costeras.

La dinámica de la costa es un fenómeno complejo que requiere monitorización continua, para comprender mejor los procesos que están en juego y tomar decisiones adecuadas (Masse-link *et al.*, 2016). La medición de la línea de costa es una tarea esencial en este proceso, porque permite conocer la posición actual de la costa y su tendencia temporal. No obstante, realizar esta medición con herramientas tradicionales es costoso y requiere equipos especializados.

Una aproximación que emerge es la ciencia ciudadana, la cual se aprovecha de la sinergia entre el público y los investigadores. *CoastSnap* es una reciente creación en este campo, que extrae datos sobre la ubicación de las líneas de costa, a partir de imágenes de fuentes diversas, para registrar los cambios en las líneas de costa a lo largo de períodos continuos y prolongados (Harley *et al.*, 2019).

Aunque *CoastSnap* ha sido adoptado con éxito en cientos de playas, el código que permite el análisis de imágenes requiere de la plataforma propietaria MATLAB para su operación

(Becker, Brown, Bricheno y Wolf, 2020). Como resultado, las costosas tarifas de licencia de MATLAB, así como las habilidades requeridas para su operación, representan una barrera continua para las comunidades con recursos limitados (Heaney, 2021).

Esta barrera podría minimizarse, pues existen alternativas gratuitas a MATLAB. *Python* es la alternativa más adecuada a MATLAB, dada la creciente adopción de este lenguaje de programación entre la comunidad de ciencia e ingeniería costera, con la inclusión de proyectos similares a *CoastSnap* (Conlin, Adams, Wilkinson, Dusek, Palmsten y Brown, 2020).

Este estudio tiene como antecedente el trabajo de Heaney (2021), que plantea investigar y comenzar la conversión de *CoastSnap* de MATLAB a *Python*. Se pretende desarrollar un producto completo y soberano para la medición de línea de costa, con el empleo de la metodología de Harley *et al.* (2019) y, además, con la capacidad de predecir su comportamiento, lo que contribuirá a la mitigación y adaptación a los riesgos costeros aumentados, debido al aumento del nivel del mar y los cambios en el clima de las olas.

Por tanto, el objetivo general de este trabajo es desarrollar una herramienta informática que posibilite la medición y predicción del cambio de la línea de costa, a partir de imágenes obtenidas de diversas fuentes.

METODOLOGÍA

HERRAMIENTAS Y TECNOLOGÍAS

Para el desarrollo del producto informático se utilizó:

- *Python*, por ser un lenguaje de programación de código abierto que cuenta con librerías para el aprendizaje automático y el análisis de datos.
- *Visual Studio Code*, como editor de código fuente, por ser multiplataforma que ofrece extensiones para diferentes lenguajes de programación, incluido *Python*.
- *PostgreSQL*, como sistema de base de datos relacional de objetos, por ser de código abierto y ofrecer opciones avanzadas como el control de concurrencias multiversión.

FLUJO DE LA APLICACIÓN

A continuación, se listan los pasos que sigue el flujo de la aplicación (figura 1):

1. Los usuarios del sistema deben cargar las imágenes obtenidas de fuentes como cámaras, *smartphones* o redes sociales, previamente seleccionadas por su calidad y correspondencia con el lugar, a la herramienta desarrollada, renombradas a la convención de nomenclatura que se determinó durante el desarrollo, para lograr uniformidad en la entrada (UnixTime.Day.Month.DD_HH_MM_SS.TimeZone.YYYY.Site.Type.Username.jpg).

2. El algoritmo transforma la imagen de coordenadas píxel (UV) a coordenadas en un sistema de referencia tridimensional (X, Y, Z), a partir de la matriz de proyección

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = P \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}. \text{ Los puntos de control de tierra inspeccionados resuelven la distancia focal}$$

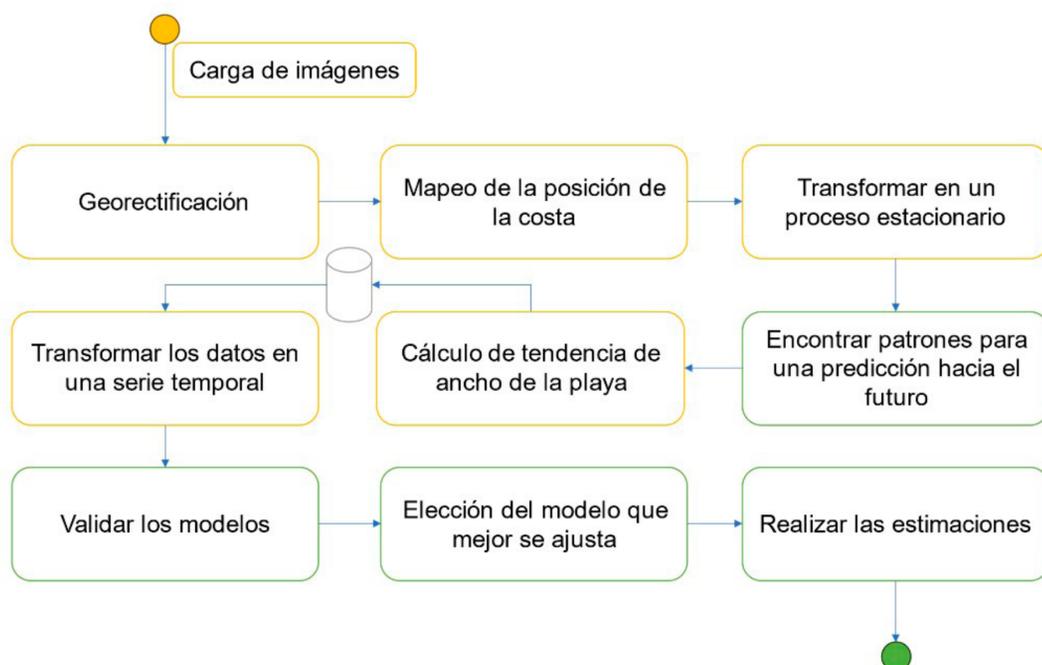


Fig. 1
Gráfico que ilustra
la metodología
(Fuente: elaboración
propia).

de la lente del teléfono inteligente y solventan con mayor precisión los parámetros extrínsecos de la cámara. El proceso de alinear digitalmente una imagen, a partir de marcar un número de puntos de control correspondientes, que se convierten en puntos de referencia para el procesamiento posterior de la imagen, se le llama georrectificación o rectificación geográfica (Esri Support, s.f.).

3. Luego del procesamiento se mapea la posición de la costa en las imágenes georectificadas, mediante la técnica de detección de bordes basada en los canales de color rojo y azul (*Red minus Blue*), que se ejemplifica en la figura 2.

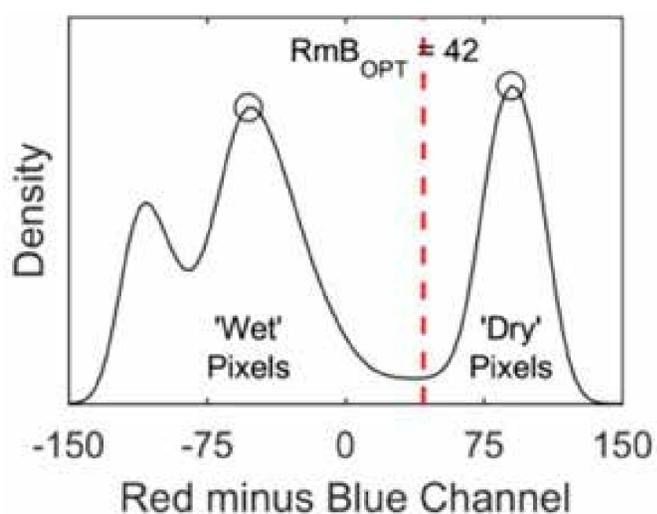


Fig. 2 Interfaz *wet and dry* de pixeles,
basado en canales de color rojo/azul (RmB)
(Harley, 2019).

4. La variable en cuestión se mide desde un punto de referencia en tierra hasta la línea de costa; luego la tendencia de ancho de la playa se calcula a partir de todas las líneas de costa en la base de datos con un nivel de marea similar, determinado por la marea astronómica al momento de la captura y el desplazamiento vertical según la configuración característica de las olas medidas en campo.
5. Los datos de la medición, obtenidos de la base de datos de la herramienta, se transforman en una serie temporal; sin embargo, plantear la fecha final de la muestra no es necesario, pues los datos de la variable que se mide están en constante crecimiento y, según la cantidad de datos proporcionados por la base de datos, el algoritmo será capaz de calcular la fecha final a partir de la inicial. Durante este paso también se reemplazan los valores perdidos del sistema y el usuario por estimaciones.

Para aplicar el modelo autorregresivo integrado de promedio móvil (ARIMA, por sus siglas en inglés), se requiere primero transformar la serie temporal en un proceso estacionario. Para ello, se emplea el cálculo de la función acumulada de probabilidad (1) (p -valor), con la condición de que la función de distribución de probabilidad de cualquier conjunto de k variables (donde k es un número finito) del proceso, se mantenga estable e inalterable al desplazar las variables s períodos de tiempo. Es decir, si $P(y_{t+1}, y_{t+2}, \dots, y_{t+k})$ es la función de distribución acumulada de probabilidad, entonces se debe cumplir que:

$$(1) \quad P(y_{t+1}, y_{t+2}, \dots, y_{t+k}) = P(y_{t+1+s}, y_{t+2+s}, \dots, y_{t+k+s}), \quad \forall t, k, s$$

En caso de que el p -valor sea mayor que 0,05 se aplica la prueba *Augmented Dickey-Fuller* (ADF) y se hacen las diferenciaciones necesarias, hasta que el p -valor sea menor que 0,05, lo cual demuestra que la serie es estacionaria. Si se quiere determinar el número de diferenciaciones necesarias para que la serie sea estacionaria en media, así como para realizar la prueba ADF y calcular el p -valor, se utiliza la librería de *Python: statsmodels*.

6. Se aplica el modelo ARIMA a la serie estacional obtenida, con el fin de encontrar patrones para una predicción hacia el futuro. La librería *statsmodels* proporciona la función ARIMA y SARIMAX, que es una extensión del modelo ARIMA que tiene en cuenta factores estacionales adicionales (Morales, 2021).
7. Para validar los modelos se realiza la prueba *Ljung-Box*, cuyos resultados deben aceptar la hipótesis nula en todos los modelos, lo que significa que los residuales se distribuyen como ruido blanco, implicando que los modelos presentan estacionariedad, normalidad e independencia, lo que los hace adecuados para la predicción (Virguez, 2018) (figura 3).

```

C:\Windows\System32\cmd.exe
=====
Dep. Variable:          OD      No. Observations:          53
Model:                ARIMA(1, 1, 1)  Log Likelihood            -46.031
Date:                 Wed, 30 Nov 2022  AIC                        98.062
Time:                 20:17:34      BIC                       103.915
Sample:               0              HQIC                      100.306
                   - 53
Covariance Type:      opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ar.L1          0.1969      0.181          1.088      0.277      -0.158      0.552
ma.L1         -1.0000     152.573         -0.007      0.995     -300.038     298.038
sigma2         0.3210      48.947          0.007      0.995     -95.614      96.256
=====
Ljung-Box (L1) (Q):          0.01      Jarque-Bera (JB):          1.60
Prob(Q):                   0.94      Prob(JB):                   0.45
Heteroskedasticity (H):     0.43      Skew:                       -0.41
Prob(H) (two-sided):        0.09      Kurtosis:                   2.74
=====

```

Fig. 3 Resultado prueba *Ljung-Box* generado por *Python*, que acepta la hipótesis nula (Fuente: elaboración propia).

- Para la elección del modelo que mejor se ajusta (ARIMA o SARIMAX) se calcula la medida de información de *Akaike* (AIC), que proporciona un medio para la selección del modelo (Inga Santiváñez, 2015), es seleccionado el de menor AIC, lo que garantiza que el modelo elegido presente menor pérdida de información (Figuras 4 y 5).

```

=====
                        ARIMA Results
=====
Dep. Variable:          OD      No. Observations:      53
Model:                 ARIMA(1, 1, 1)  Log Likelihood         -46.031
Date:                  Wed, 30 Nov 2022  AIC                    88.346
Time:                  20:17:34      BIC                    103.915
Sample:                0          HQIC                   100.306
                        - 53
Covariance Type:      opg
=====
    
```

Fig. 4 Resumen Modelo ARIMA (1, 1, 1) para los datos de prueba. Este es el modelo elegido (Fuente: elaboración propia).

```

=====
                        SARIMAX Results
=====
Dep. Variable:          y      No. Observations:      53
Model:                 SARIMAX(1, 1, 1, 12)  Log Likelihood         -40.173
Date:                  Wed, 30 Nov 2022  AIC                    98.062
Time:                  20:17:34      BIC                    96.227
Sample:                0          HQIC                   91.377
                        - 53
Covariance Type:      opg
=====
    
```

Fig. 5 Resumen modelo SARIMAX (1, 1, 1, 12) para los datos de prueba (Fuente: elaboración propia).

- Después de obtener el modelo más ajustado a los datos, se realizan las estimaciones. Para esto se utiliza la función *forecast* de la librería de igual nombre.

RESULTADOS Y DISCUSIÓN

Los resultados, que se exponen a continuación, están estructurados según las etapas metodológicas y con el uso de la herramienta desarrollada. Los datos históricos utilizados para las pruebas se generaron con estimaciones y se mezclaron con mediciones realizadas por la herramienta, debido a que no se encontró en la revisión bibliográfica documentación sobre el comportamiento de esta variable en Cuba, ni un registro público de mediciones de esta variable en otras costas del mundo.

Como se observa en las figuras 6 y 7, el patrón detectado coincide con el histórico de datos, dado que la variable tiende a disminuir su valor, por lo que se observa un retroceso de la extensión de la costa que puede asociarse comúnmente a factores como la erosión costera, subsidencia del terreno, cambios geológicos o la acción humana (Merlotto y Bértola, 2009). La predicción obtenida puede servir al gestor ambiental, para observar estos agentes externos

que pueden estar influyendo de forma negativa sobre la variable de estudio y aplicar acciones tempranas para corregir este comportamiento. En un caso de uso como este, se demuestra el valor de la herramienta para la toma de decisiones informadas que puedan contribuir a mitigar los efectos de la variación de la extensión de la costa y proteger áreas vulnerables.

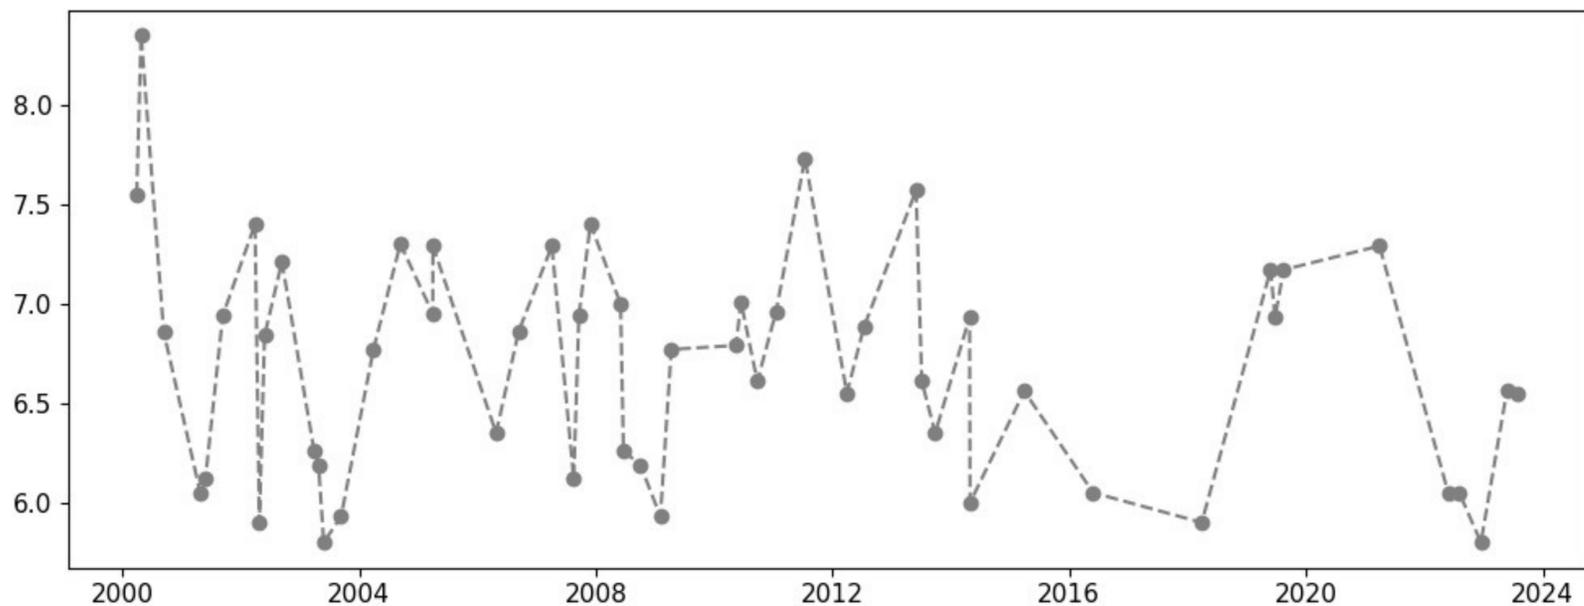


Fig. 6 Comportamiento de la variable en los datos de prueba (Fuente: elaboración propia).

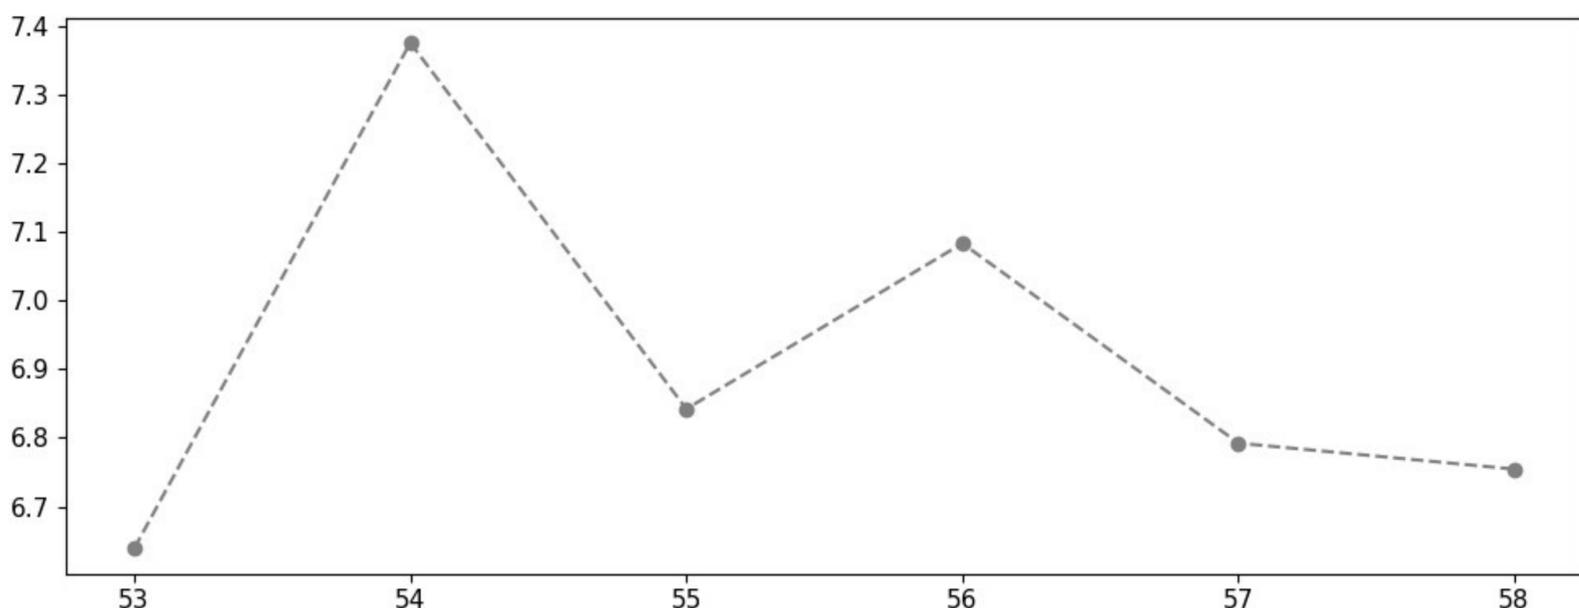


Fig. 7 Predicción del comportamiento de la variable realizada por el modelo, para los datos de prueba (Fuente: elaboración propia).

Para evaluar los modelos propuestos, se utilizó el indicador de Porcentaje de Error Medio Absoluto (2) (MAPE), debido a su fácil interpretación. Según el MAPE, la clasificación del pronóstico depende del porcentaje de error obtenido. En las pruebas realizadas se obtuvieron valores de MAPE de 4,58 % (figura 8), lo que significa que el modelo es altamente confiable para predecir escenarios futuros.

El MAPE se calcula de la siguiente forma:

$$(2) \quad MAPE = \frac{\sum_{t=1}^n \left| \frac{(y_t - \hat{y}_t)(100)}{y_t} \right|}{n}$$

Donde:

- y_t : es el valor observado (valor real del indicador)
- \hat{y}_t : es el valor pronosticado (predicción del indicador)
- n : es la cantidad de observaciones

```
Name: Predicciones ARIMA, dtype: float64
.....MAPE.....
4.581749743056838
```

% de Error MAPE	Clasificación del pronóstico
Menor de 10%	Alta precisión
10% -20%	Buena precisión
20% - 50%	Precisión razonable
Mayor del 50%	Poco fiable



Fig. 8 Cálculo del MAPE para evaluar el modelo de predicción utilizado con los datos de prueba (Fuente: elaboración propia).

El empleo de una alternativa de *software* libre, como la herramienta para medir y predecir el cambio de la línea de costa, basada en la metodología expuesta, propone un cambio de paradigma en el cual países sin acceso a licencias de *software* privativo pueden aprovechar las potencialidades de las tecnologías de la información y las comunicaciones (TIC), para aplicarlas a la gestión ambiental.

CONCLUSIONES

Se propuso una metodología basada en el empleo de *software* libre como herramienta que permite medir el comportamiento de la línea de costa y mostrar su tendencia temporal. Se implementaron los algoritmos para la predicción del comportamiento de la línea de costa, lo que permitirá que los gestores ambientales tomen decisiones informadas para mitigar los efectos de la variación de la extensión de la costa.

El análisis del modelo de datos analizados permitió inferir que el retroceso de la extensión de la costa puede asociarse principalmente a factores como la erosión costera, subsidencia del terreno, cambios geológicos o la acción humana. Se evaluó la veracidad del modelo propuesto a partir del empleo del MAPE, que arrojó valores inferiores al 10 %, lo que significa que el modelo es altamente confiable para predecir escenarios futuros.

REFERENCIAS

Becker, A., Brown J., Bricheno, L., Wolf, J. (2020). Guidance note on the application of coastal monitoring for small island developing states: Part of the NOC-led project “Climate Change

- Impact Assessment: Ocean Modelling and Monitoring for the Caribbean CME states”, 2017-2020; under the Commonwealth Marine Economies (CME) Programme in the Caribbean. Southampton, National Oceanography Centre, 40pp. (National Oceanography Centre Research and Consultancy Report, 74). <https://nora.nerc.ac.uk/id/eprint/527224>
- Conlin, M. P., Adams, P. N., Wilkinson, B., Dusek, G., Palmsten, M. L., & Brown, J. A. (2020). SurfRCaT: A tool for remote calibration of pre-existing coastal cameras to enable their use as quantitative coastal monitoring tools. *SoftwareX*, 12, 100584. <https://doi.org/10.1016/j.softx.2020.100584>
- Esri Support. (s.f.). Definición de Rectificación Geográfica. Recuperado de <https://support.esri.com/es-es/gis-dictionary/georectification>
- Harley, M. D., Kinsela, M. A., Sánchez-García, E., & Vos, K. (2019). Shoreline change mapping using crowd-sourced smartphone images. *Coastal Engineering*, (150): 175-189. <https://doi.org/10.1016/j.coastaleng.2019.04.003>
- Heaney, N. (2021). Towards the conversion of CoastSnap to an open source citizen science tool for coastal monitoring. University of Edimburgh.
- Inga Santiváñez, R. M. (2015). El criterio de información de Akaike en el análisis de datos categorizados (Tesis doctoral). Universidad Complutense de Madrid, España. Recuperado de: <https://eprints.ucm.es/id/eprint/53832/1/5320609308.pdf>
- Masselink, G., Castelle, B., Scott, T., Dodet, G., Suanez, S., Jackson, D., & Floc’h, F. (2016). Extreme wave activity during 2013/2014 winter and morphological impacts along the Atlantic coast of Europe. *Geophysical Research Letters*, 43(5): 2135-2143. <https://doi.org/10.1002/2015GL067492>
- Merlotto, A, & Bértola, GR. (2009). Coastline evolution at Balneario Parque Mar Chiquita, Argentina. *Ciencias marinas*, 35(3), 271-286. Recuperado de: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0185-38802009000300003&lng=es&tlng=, 15 de julio de 2023,
- Morales, V. (2020). Modelización de series univariantes SARIMA. Series de Tiempo con R. Recuperado de https://bookdown.org/victor_morales/SeriesdeTiempo/modelizaci%C3%B3n-de-series-univariantes-sarima.html
- Virguez, J. W. (2018). Modelo de pronóstico PIB financiero. Recuperado de: <http://hdl.handle.net/11371/2130>.

