

Artículo de Investigación

La inteligencia artificial en la predicción de la temperatura ambiental y del suelo en Ecuador

Artificial intelligence in the prediction of environmental and soil temperature in Ecuador

Ángel Ramón Sabando-García: Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD), Ecuador.

arsabando@pucesd.edu.ec

Mikel Ugando Peñate: Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD), Ecuador.

mugandop@pucesd.edu.ec

Reinaldo Armas Herrera: Universidad Técnica Particular de Loja (UTPL), Ecuador.

ahreinaldo@utpl.edu.ec

Angel Alexander Higuerey Gómez: Universidad Técnica Particular de Loja (UTPL), Ecuador.

aahiguerey@utpl.edu.ec

Néstor Leopoldo Tarazona Meza: Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López. Ecuador.

nestor.tarazona@espam.edu.ec

Pierina D'Elia Di Michele: Universidad Técnica Particular de Loja (UTPL), Ecuador.

pdelia@utpl.edu.ec

Elvia Rosalía Inga Llenez: Universidad Técnica Particular de Loja (UTPL), Ecuador.

eringa1@utpl.edu.ec

Fecha de Recepción: 26/11/2024

Fecha de Aceptación: 27/12/2024

Fecha de Publicación: 01/01/2025

Cómo citar el artículo

Sabando-García, Á. R., Ugando Peñate, M., Armas Herrera, R., Higuerey Gómez, A. A. Tarazona Meza, N. L., D'Elia Di Michele, P. e Inga Llenez, E. R. (2025). La inteligencia artificial en la predicción de la temperatura ambiental y del suelo en Ecuadorl [Artificial intelligence in the prediction of environmental and soil temperature in Ecuador]. *European Public & Social Innovation Review*, 10, 01-17. <https://doi.org/10.31637/epsir-2025-550>

Resumen

Introducción: El estudio tuvo como objetivo principal analizar la probabilidad y predicción para la temperatura ambiental y el suelo en la zona costera de Manabí en Ecuador. **Metodología:** La metodología hace uso de series de tiempo Box Jenkins ARIMA y de comparación de medias. Los datos se midieron a las 07:00 am, 12:00 pm y 18:00pm, iniciando en enero de 2015 hasta diciembre del 2020. Los datos se analizaron y procesaron con la ayuda de la inteligencia artificial incorporada al software RStudio. **Resultados:** Los resultados, evidencian que la temperatura del suelo está correlacionada con la temperatura ambiental. **Discusión:** Las pruebas de bondades de ajuste para los coeficientes y supuestos validaron el modelo ARIMA observado y esperado. Además, los criterios AIC y BIC se utilizaron para escoger el mejor modelo predictivo. **Conclusiones:** En conclusión, la inteligencia artificial identificó que la predicción de las temperaturas ambiental y del suelo son simuladas adecuadamente a través de un modelo ARIMA(0,1,1)(0,1,1)[12], con componentes de tendencia y estacionalidad; afirmando un modelo de series de tiempo no estacionario. Se llega a determinar que, la temperatura tiene una pequeña variabilidad por cada periodo de tiempo, pero en aumento, y en lo posterior probablemente este factor climático se convierta en un determinante del calentamiento global.

Palabras clave: Series de tiempo, temperatura suelo, temperatura ambiente, inteligencia artificial, pronósticos, algoritmos supervisados, Ecuador, ARIMA.

Abstract

Introduction: The main objective of the study was to analyze the probability and prediction for environmental and soil temperature in the coastal area of Manabí in Ecuador. **Methodology:** The methodology makes use of Box Jenkins ARIMA time series and comparison of means. The data was measured at 07:00 am, 12:00 pm and 18:00 pm, starting in January 2015 until December 2020. The data was analyzed and processed with the help of artificial intelligence incorporated into the RStudio software. **Results:** The results show that soil temperature is correlated with environmental temperature. **Discussions:** Goodness-of-fit tests for the coefficients and assumptions validated the observed and expected ARIMA model. Furthermore, the AIC and BIC criteria were used to choose the best predictive model. **Conclusions:** In conclusion, artificial intelligence identified that the prediction of ambient and soil temperatures are adequately simulated through an ARIMA(0,1,1)(0,1,1)[12] model, with trend and seasonality components, By affirming a non-stationary time series model, it is determined that temperature has a small variability for each period of time, but increasing, and in the future this climatic factor will probably become a determinant of global warming.

Keywords: Time series, soil temperature, ambient temperature, artificial intelligence, forecasts, supervised algorithms, Ecuador, ARIMA.

1. Introducción

Los modelos autorregresivos integrados de media móvil de Box-Jenkins (ARIMA) son muy empleados en la identificación de modelos predictivos, en la comprobación diagnóstica y en la predicción de factores climáticos (Tang *et al.*, 2023; Xiaowei *et al.*, 2022). Los modelos ARIMA producen los errores de pronóstico más bajos en esta clase de investigaciones (Guo *et al.*, 2023) y la rigurosa aplicación comparativa de series temporales avanzadas y técnicas de aprendizaje automático proporcionan información valiosa para la toma de decisiones (Mishra *et al.*, 2023). El uso de estos modelos en la predicción de la temperatura es óptimo (Dimri. *et al.* 2020; Yi-Hui *et al.*, 2020). Para ello, hay que recopilar los datos históricos registrados en el campo y luego ser validados (Ortega-Ballesteros *et al.* 2023).

Los modelos de series de tiempo homocedásticos y heterocedásticos son los más adecuados para pronosticar las temperaturas mínimas, máximas y la humedad relativa (Mishra *et al.* 2021). Las fluctuaciones actuales de la temperatura y otras condiciones climáticas tienen un impacto significativo en la situación actual del medioambiente (Guo *et al.*, 2023). Cuando la humedad relativa disminuye, la temperatura aumenta, disminuyendo la capacidad del aire para retener el agua (Aaishah-Radziah *et al.*, 2015). La técnica ARIMA es considerada como el mejor modelo matemático al pasar las pruebas de normalidad y de evaluación de los pronósticos, Error porcentual absoluto promedio (MAPE), Error promedio cuadrático (MSE) y la puntuación estacionaria (Shangguan *et al.* 2022; Sabando *et al.*, 2022).

Los ARIMA y los ARIMA estacionales (SARIMA) son técnicas comunes que se utilizan ampliamente en el análisis y la predicción de datos de series temporales estacionarias y estacionales. En ocasiones el modelo ARIMA puede presentar estacionalidad, en ese caso se emplearía el modelo SARIMA, que es una forma alternativa de estimar los parámetros. En estos casos mejoran el rendimiento del modelo ARIMA para pronosticar parámetros en datos como la temperatura (Farsi *et al.* 2020; Tang *et al.* 2023). En el artículo de Farsi *et al.* (2020), el modelo ARIMA se encuentra como el modelo de mejor ajuste mostrando una excelente concordancia con los factores climáticos observados en el período de validación, lo que justifica su aplicabilidad para el pronóstico futuro de las condiciones climáticas (Swain *et al.*, 2022). Este también se usa para pronosticar el nivel de las aguas subterráneas en series temporales (Sagarika *et al.* 2023) y la sequía hidrológica, que tiene una estrecha relación con la evolución de los índices climáticos (Wu *et al.* 2020).

En este sentido, el modelo entrenado genera el mejor desempeño en función del comportamiento de la variable. Esto sugiere que los modelos de predicción varían entre regiones y que la selección del modelo de predicción óptimo depende de los procesos físicos dominantes que gobiernan los factores (Abdul-Lateef y Naheem 2021). La modelización y la predicción de las condiciones climáticas puede ayudar a determinar los efectos de los cambios estacionales en el clima durante un período de tiempo específico (Gokul-Krishnan *et al.* 2023). De acuerdo con Hosseinzadeh *et al.* (2023), la temperatura y la precipitación aumentan la precisión de las predicciones hídricas. Nyatuame & Agodzo (2018), para predecir la lluvia anual y la temperatura de una cuenca de un río en Ghana, determinaron que el mejor modelo es ARIMA para las temperaturas máximas en diferentes regiones.

La aplicación de técnicas estadísticas es crucial para comprender los fenómenos que influyen en la toma de decisiones. Para medir la idoneidad de los modelos, hay múltiples criterios como el Akaike (AIC), el Akaike ajustado (AICc), el índice del coeficiente bayesiano (BIC) y el valor de las varianzas (σ^2). Estos criterios determinan que modelo es el apropiado para predecir la temperatura superficial en el continente africano (Afrifa-Yamoah, 2015). El desempeño de éstos se mide en términos de Raíz del error promedio cuadrático (RMSE) y Error promedio absoluto (MAE) (Prashant, 2016), mientras que la precisión de estos modelos se evalúa en función del coeficiente de determinación (R^2) (Tang *et al.*, 2023; Dehbalaei *et al.* 2023).

La función Autoarima en RStudio realiza muchas combinaciones o iteraciones mediante la inteligencia artificial para seleccionar el mejor modelo ARIMA. Se analizaron estadísticamente estos modelos utilizando el coeficiente de correlación, el criterio BIC, el RMSE, criterio MAPE, el valor T de Student y su valor probabilístico (Pradeep *et al.*, 2022; Tang *et al.*, 2023; Gokul-Krishnan *et al.*, 2023).

Por su parte, Dabral (2017) identificó como criterios de selección para el modelo ARIMA, la función de autocorrelación simple (ACF), la función de autocorrelación parcial (PACF), los valores mínimos del AIC, el criterio de Schwarz de información bayesiana (SBC), la correlación estacionaria y la prueba de Ljung-Box Q de los residuos.

Antes de identificar el modelo, se analiza si la serie de datos es estacionaria o no, condición que debe cumplirse para obtener el modelo ARIMA. La serie de datos original se somete a la prueba de Dickey-Fuller aumentada para confirmar la estacionariedad o no de los datos. Si la serie no es estacionaria debe transformarse para hacerla estacionaria (Ortega-Ballesteros *et al.* 2023). Además, se emplearon otras pruebas como la Mann-Kendall (MK) y la Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (Gokul-Krishnan *et al.* 2023). Adicionalmente, se usó la prueba de Ljung-Box, la de heterocedasticidad y la de Kolmogorov - Smirnov para crear, calibrar y evaluar el modelo en el intervalo de confianza del 95% (Zolghadr-Asli *et al.*, 2021).

Este estudio se enfoca en el uso de modelos de inteligencia artificial y aprendizaje automático en el campo de la estimación y predicción de parámetros, tal como lo describe Alaa-Ali & Dmitry (2023). El enfoque de pronóstico utilizó técnicas estocásticas (ARIMA y SARIMA) y de aprendizaje automático (Kheimi *et al.* 2023). Los modelos de inteligencia predicen que la temperatura aumentará continuamente más allá del año 2050 (Antoinette-Marie *et al.*, 2020). Por otra parte, los modelos de series de tiempo con media móvil y varianza constante, complementados con la inteligencia artificial, mostraron índices climáticos potenciales para mejorar el rendimiento de los modelos empleados (Kim *et al.* 2019).

Así mismo, Wang *et al.* (2019) destacan que el modelo ARIMA mediante la inteligencia artificial puede mejorar eficazmente la precisión de la predicción de la temperatura y caracterizar mejor el comportamiento de las variables climáticas. Los modelos SARIMA pueden tener una mejor capacidad para pronosticar las variaciones estacionales en los factores climáticos (Yang y Xing, 2022). Estos modelos mejoran hasta tres veces la precisión de los modelos independientes basados en la medida de eficiencia (Danandeh-Mehr *et al.* 2022).

Esta investigación tiene varios objetivos; uno es determinar si existe correlación de la temperatura ambiental con la temperatura del suelo a 20 cm. y el segundo es establecer la predicción de la temperatura ambiental y suelo en el litoral ecuatoriano a través de modelos ARIMA con el uso de la inteligencia artificial.

2. Metodología

La metodología hace uso de modelos probabilísticos de series de tiempo Box Jenkins - ARIMA y de comparación de medias, con un enfoque cuantitativo, retrospectivo, prospectivo, correlacional y comparativo. El estudio se realizó en la zona costa de la provincia de Manabí en Ecuador. Los datos agroclimáticos como la temperatura ambiental y subterránea se registraron de las estaciones agrometeorológicas de la Escuela Superior Politécnica Agropecuaria de Manabí (ESPAM), entre las coordenadas geográficas: Latitud 0° 49' 10"; longitud 80° 10' 40" oeste; altitud 15 metros sobre el nivel del mar, durante el inicio del año 2015 hasta la culminación del año 2020.

Para medir la temperatura del suelo, se instaló un termómetro a una profundidad de 20 cm. de la superficie del suelo, que no poseía cobertura vegetal y se determinó en grados Celsius. A esta profundidad se realiza la mayor actividad de la fauna y flora del suelo, y de las raíces de las plantas de captar los nutrientes.

La temperatura ambiental y del suelo se medía al amanecer, mediodía y atardecer. En total se registraron 13.140 datos, que posteriormente se promediaron, quedando disponibles 2.193 observaciones para la temperatura promedio del suelo y en la misma cantidad para la temperatura ambiental. Para llevar a cabo el análisis de los datos y la aplicación predictiva de series de tiempo con respecto a las temperaturas se hizo uso de la inteligencia artificial con el software de lenguaje programación RStudio versión 4.1.2.

2.1 Análisis estadístico mediante inteligencia artificial

Inicialmente, se realizaron una serie de pruebas estadísticas en el campo de las series de tiempo; la prueba de Dickey-Fuller aumentada para determinar estacionariedad ($p < 0.05$); la prueba de Ljung-Box que mide el ruido blanco ($p > 0.05$), la prueba Bartlett que mide la homocedasticidad ($p > 0.05$) y el contraste de normalidad de Kolmogorov-Smirnov con fin de determinar la normalidad de los datos ($p > 0.05$). Estas pruebas son necesarias para entrenar, calibrar y evaluar el modelo con un intervalo de confianza del 95% (Zolghadr-Asli *et al.* 2021).

Se complementa el proceso de la simulación con otras pruebas complementarias como la correlación estacionaria, que se emplea para seleccionar el mejor coeficiente para entrenar los modelos. Esto implica calcular la correlación por pares de todas las variables (Abdul-Lateef y Naheem, 2021). Del mismo modo, se realiza un análisis gráfico de las funciones PACF y ACF para los residuos (Hu *et al.* 2021; Box *et al.* 2015).


En algunos pronósticos se presentan los componentes de estacionalidad y de tendencia, por lo que se determina el modelo como SARIMA. En este sentido, los parámetros de bondad de ajuste del modelo, el MAPE, el MSE y la correlación estacionaria (Shangguan *et al.* 2022), miden la eficiencia del modelo en función de la magnitud del modelo predictivo (Fu *et al.*, 2019), y generan una mayor confiabilidad en los parámetros de la estimación (Ugando-Peñate *et al.* 2021). Por supuesto, habrá que aplicar las pruebas de diagnóstico para determinar si el modelo ARIMA elegido es razonablemente exacto (Hu *et al.* 2021). Además, otras de las pruebas que generan confiabilidad es el criterio AIC y AICc (Burnham & Anderson, 2002; Hurvich y Tsai, 1989; Brockwell & Davis, 1991; McQuarrie y Tsai, 1998); complementado con el criterio BIC (Yang y Xing, 2022).

3. Resultados

En la figura 1, mediante el análisis estadístico complementada con la inteligencia artificial, se valida el objetivo planteado sobre la correlación de la temperatura ambiental y su incidencia en la temperatura del suelo a 20 cm de profundidad. La correlación de Pearson mostró un valor significativo ($p < 0.05$) entre la temperatura ambiente y la temperatura del suelo; es decir, a medida que aumenta la temperatura ambiente, simultáneamente se incrementa la temperatura del suelo. Las pruebas de bondad de ajuste, correlación de Pearson, test T de Student, P-value y los intervalos de confianza al 0,05 de significancia, justifican la relación entre las dos variables climáticas, tal como lo describe Coutinho *et al.* (2023).

Figura 1.

Correlación de Pearson de la temperatura promedio del suelo en función de la temperatura promedio ambiental en el litoral ecuatoriano



Nota: Promedio temperatura suelo y promedio temperatura ambiental; $t = 7.2762$, $df = 2.191$, $p\text{-value} = 4,759e-13$
hipótesis alternativa: verdadera correlación no es igual con un intervalo de confianza del 95%: 0.1124689
0.1942119 R^2 estimado de la muestra = 0,1536032

Fuente: Elaboración propia (2025).

Con la finalidad de realizar el segundo objetivo, sobre la predicción de la temperatura ambiental y suelo en el litoral ecuatoriano, a través de una serie de tiempo de Box Jenkins, con la aplicación de un modelo ARIMA, inicialmente la variable temperatura ambiente registró una serie de tiempo no estacionaria ($p=0,2684$), y fue necesario volverla estacionaria mediante una diferencia en la raíz unitaria de Dickey-Fuller ($p=0,0100$); hallazgo que se aprecian en la tabla 1. En esta misma línea, la temperatura del suelo también registró una tendencia positiva (no estacionaria) según la prueba Dickey-Fuller ($p=0,3765$), y se llevó a estacionaria con una diferencia. La prueba de Dickey- Fuller deja claro que la temperatura ambiental y la del suelo se están elevando en los cinco años de estudio de este experimento.

Tabla 1.

Test de Dickey Fuller para determinar no estacionariedad y no estacionariedad para las temperaturas


Test	Diferencia (MA)	Coeficiente	Lag order	p-value	Hipótesis
Series de tiempo de la temperatura ambiental (°C)					
Dickey-Fuller	0	-2.7537	4	0.2684	No estacionaria
Dickey-Fuller	1	-6.3551	4	0.0100	Estacionaria
Series de tiempo de la temperatura suelo (°C)					
Dickey-Fuller	0	-2.4884	4	0.3765	No estacionaria
Dickey-Fuller	1	-4.8096	4	0.0100	Estacionaria

Fuente: Elaboración propia (2025).

En la figura 2 se visualiza el comportamiento de la descomposición de la serie de tiempo de las temperaturas ambiente y suelo, en la cual se visualiza que las variables en estudio poseen tendencia y estacionalidad; dejando claro que la temperatura ambiente y suelo tiene una tendencia positiva y con cierto comportamiento estacional. Estos sucesos se repiten con frecuencia en cada periodo temporal. La tabla 2 recoge la clasificación de modelos ARIMA para la temperatura del suelo y la ambiental.

Figura 2.

Comportamiento de la descomposición de las series de tiempo temperatura del suelo y temperatura ambiente



Fuente: Elaboración propia (2025).

Tabla 2.

Iteraciones de los modelos ARIMA para las temperaturas ambiental y suelo

Nº	Número de iteraciones	Criterio Akaike	Nº	Número de iteraciones	Criterio Akaike
11	ARIMA(0,1,1)(0,1,1)[12]	171,9352	11	ARIMA(0,1,1)(0,1,1)[12]	133,8129
20	ARIMA (0,1,2)(0,1,1)[12]	172,5847	47	ARIMA(1,1,1)(0,1,1)[12]	135,7895
47	ARIMA(1,1,1)(0,1,1)[12]	172,9793	20	ARIMA(0,1,2)(0,1,1)[12]	135,9262
55	ARIMA(1,1,2)(0,1,1)[12]	173,6537	13	ARIMA(0,1,1)(1,1,0)[12]	138,0974
12	ARIMA(0,1,1)(0,1,2)[12]	174,1017	16	ARIMA(0,1,1)(2,1,0)[12]	139,1484
14	ARIMA(0,1,1)(1,1,1)[12]	174,1064	57	ARIMA(1,1,2)(1,1,0)[12]	139,8875
28	ARIMA(0,1,3)(0,1,1)[12]	174,1218	49	ARIMA(1,1,1)(1,1,0)[12]	139,9318
16	ARIMA(0,1,1)(2,1,0)[12]	174,1911	22	ARIMA(0,1,2)(1,1,0)[12]	140,0697
73	ARIMA(2,1,1)(0,1,1)[12]	174,4478	35	ARIMA(0,1,4)(1,1,0)[12]	140,643
23	ARIMA(0,1,2)(1,1,1)[12]	174,9333	59	ARIMA(1,1,2)(2,1,0)[12]	140,8182

Fuente: Elaboración propia (2025).

En la tabla 2, se visualiza las primeras diez iteraciones, de un total de 96, de la temperatura ambiental y del suelo mediante la función Autoarima de la inteligencia artificial. El algoritmo seleccionó para la temperatura ambiente el modelo ARIMA (0,1,1) (0,1,1) [12]. El algoritmo escoge el modelo 11 de 96 iteraciones. De igual modo, la temperatura del suelo presentó un modelo ARIMA (0,1,1) (0,1) [12], seleccionando el algoritmo el modelo 11 de 96 posibles. Se deja en evidencia que las temperaturas, suelo y ambiente presentan tendencia y estacionalidad. La tabla 3 visualiza las pruebas de ajuste para los modelos seleccionados.

Tabla 3.

Prueba de ajuste del modelo ARIMA para las temperaturas ambiental y suelo

Prueba de ajuste	Series: Temperatura ambiental		Series: temperatura del suelo	
Modelo	ARIMA(0,1,1)(0,1,1)[12]		ARIMA (0,1,1)(0,1,1)[12]	
Acrónimos	ma1	sma1	ma1	sma1
Coeficientes	-0.7645	-0.5988	-0.7825	-0.8177
Error estándar	0.1048	0.1683	0.0960	0.3557
Criterios	AIC=133.38 AICc=133.81 BIC=139.61		AIC=171.5 AICc=171.94 BIC=177.73	
Ljung-Box test	Q* = 11.634, df = 12, p-value = 0.4755		Q* = 25.226, df = 12, p-value = 0.01379	

Fuente: Elaboración propia (2025).

De los hallazgos plasmados en la tabla 3, se deduce que las temperaturas ambiente y suelo presentan estacionalidad, por lo cual se forman modelos ARIMA. El modelo de la temperatura ambiente con sus pruebas de bondad de ajuste como los criterios AIC y AICc, el criterio BIC y la prueba de Ljung Box, presentan parámetros idóneos. Comportamiento similar se registró la temperatura del suelo, pero con coeficientes de bondad más altos y la prueba de Ljung-Box indicó que esta no es un paseo aleatorio y que verse influida por otros factores climáticos. La tabla 4 refleja las pruebas de bondad de ajuste de los modelos óptimos.

Tabla 4.

Prueba de bondades de ajuste para los modelos ARIMA de la temperatura del ambiente y suelo

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
<i>Series: Temperatura ambiental: ARIMA (0,1,1) (0,1,1) [12]</i>						
0.02603594	0.8448048	0.6176819	0.0254641	2.335374	0.6837807	0.08604344
<i>Series: Temperatura suelo: ARIMA (0,1,1) (0,1,1) [12]</i>						
0.12459140	0.5770132	0.4333049	0.4040030	1.503269	0.6717906	-0.10534970

Fuente: Elaboración propia (2025).

En estos modelos predictivos ARIMA, existen otros contrastes que miden las bondades de ajuste de aquellos pronósticos como: ME, RMSE, MAE, MPE, MAPE, MASE y ACF1. En este caso la simulación de la temperatura ambiental: ARIMA (0,1,1) (0,1,1) [12], reportaron valores muy cercanos a cero. Similar comportamiento se puede visualizar para la temperatura del suelo con el modelo ARIMA (0,1,1) (0,1,1) [12]. Estas pruebas de rigurosidad no hacen más que confirmar que la técnica de series de tiempo ARIMA predice de forma excelente el factor climático de las temperaturas de ambiente y suelo en el litoral ecuatoriano. La tabla 5 visualiza los pronósticos de ambos tipos de temperatura.

Tabla 1.

Pronósticos ARIMA de las temperaturas ambiental y suelo en el litoral ecuatoriano


Fecha	Pronósticos de la temperatura ambiente (°C)			Pronósticos de la temperatura suelo (°C)		
	Forecast	Forecast Lo 95	Forecast Hi 95	Forecast	Forecast Lo 95	Forecast Hi 95
1/1/2021	28.37641	26.51310	30.23971	29.05713	27.76040	30.35386
2/1/2021	28.11547	26.20124	30.02971	29.07761	27.75079	30.40443
3/1/2021	28.38854	26.42469	30.35238	28.84927	27.49303	30.20551
4/1/2021	28.34407	26.33184	30.35630	29.23307	27.84803	30.61811
5/1/2021	27.86858	25.80911	29.92806	29.13778	27.72453	30.55102
6/1/2021	28.37273	26.26706	30.47839	29.48748	28.04658	30.92839
7/1/2021	27.95116	25.80030	30.10202	29.47580	28.00776	30.94384
8/1/2021	27.86900	25.67387	30.06412	29.45053	27.95584	30.94522
9/1/2021	28.35339	26.11487	30.59190	29.20305	27.68219	30.72391
10/1/2021	28.94484	26.66375	31.22592	29.27421	27.72762	30.82081
11/1/2021	28.52253	26.19966	30.84540	29.44219	27.87028	31.01411
12/1/2021	28.32860	25.96468	30.69251	29.40404	27.80721	31.00086
1/1/2022	28.93993	26.29304	31.58682	29.09837	27.40399	30.79274
2/1/2022	28.67900	25.96165	31.39635	29.11885	27.39107	30.84664
3/1/2022	28.95206	26.16603	31.73809	28.89051	27.12995	30.65107
4/1/2022	28.90759	26.05454	31.76065	29.27431	27.48158	31.06705
5/1/2022	28.43211	25.51356	31.35065	29.17902	27.35468	31.00336
6/1/2022	28.93625	25.95366	31.91884	29.52872	27.67331	31.38413
7/1/2022	28.51469	25.46939	31.55998	29.51704	27.63107	31.40301
8/1/2022	28.43252	25.32579	31.53926	29.49177	27.57573	31.40781
9/1/2022	28.91691	25.74993	32.08389	29.24429	27.29865	31.18994
10/1/2022	29.50836	26.28226	32.73446	29.31546	27.34065	31.29026
11/1/2022	29.08606	25.80190	32.37021	29.48344	27.47989	31.48698
12/1/2022	28.89212	25.55091	32.23333	29.44528	27.41340	31.47715
1/1/2023	29.50346	25.89275	33.11416	29.13961	27.01067	31.26855
2/1/2023	29.24252	25.54623	32.93882	29.16009	26.99510	31.32509
3/1/2023	29.51558	25.73564	33.29553	28.93175	26.73130	31.13220
4/1/2023	29.47112	25.60934	33.33290	29.31555	27.08020	31.55090
5/1/2023	28.99563	25.05371	32.93755	29.22026	26.95055	31.48997
6/1/2023	29.49977	25.47931	33.52024	29.56996	27.26640	31.87352
7/1/2023	29.07821	24.98071	33.17571	29.55828	27.22136	31.89520
8/1/2023	28.99605	24.82293	33.16916	29.53301	27.16321	31.90282
9/1/2023	29.48044	25.23305	33.72782	29.28553	26.88329	31.68778
10/1/2023	30.07188	25.75150	34.39226	29.35670	26.92244	31.79095
11/1/2023	29.64958	25.25742	34.04174	29.52468	27.05883	31.99052
12/1/2023	29.45564	24.99286	33.91843	29.48652	26.98949	31.98355

Fuente: Elaboración propia (2025).

A través del pronóstico ARIMA (0,1,1) (0,1,1)[12], se determinó que la temperatura ambiente fluctúa desde 27,86 hasta 30,07 °C desde el año 2021 hasta el año 2023, se genera una dispersión de 2,21 °C. Por su parte, la temperatura del suelo con el mismo ARIMA tiene poca variabilidad (0,72°C) que va desde 28,84 hasta 29,56 °C al 95% de confianza. La figura 3 visualiza los datos de la tabla 5.

Figura 3.

Modelos predictivos de las temperaturas ambiente y suelo en el litoral ecuatoriano



Fuente: Elaboración propia (2025).

4. Discusión

Este artículo estudia la relación entre la temperatura ambiental y del suelo en una región agrícola como es la zona costa de Manabí en Ecuador. Ambas variables están correlacionadas, por lo que se inferir que ambas variables climáticas se mueven de manera similar. La importancia de hecho radica en que, según la literatura de cambio climático, el aumento continuado de temperaturas perjudica a la productividad de esta actividad y a la rentabilidad de las empresas de este sector económico. Ecuador es un país productor de alimentos, y este es uno de sus principales sectores económicos y de exportación. A la luz de los datos, esta zona de Ecuador está en pleno proceso de cambio climático.

Esta es una de las principales limitaciones de esta investigación, ya que al ser solo una zona del país y tener un clima diferente en función de la región estudiada habría que repetir el experimento en otras zonas para confirmar que todo el país se encuentra en el mismo proceso de cambio climático. Como futuras líneas de investigación, se realizará el experimento en otras zonas del país agrícolas y se relacionará otras variables con la temperatura como la exposición solar, las precipitaciones, la productividad agrícola, la superficie cultivada, entre otras variables.

5. Conclusiones

La temperatura ambiental y la del suelo están correlacionadas en la costa ecuatoriana, lo cual supone que al medir la temperatura ambiental se conocerá en que valores está la del suelo. Esto es importante porque esta última determina la actividad de los microorganismos en la tierra, elemento esencial para la productividad agrícola. La predicción de estas variables indica que van a aumentar en el futuro, lo que indica que las condiciones climáticas van a empeorar salvo que se tomen medidas al respecto.

La temperatura va a aumentar en el futuro, pero este aumento depende en un alto grado de la actividad humana, por lo que medidas que reduzcan las emisiones de gases de efecto invernadero pueden hacer que la situación sea más sostenible. Los agricultores y las empresas que se dedican a la agricultura deben invertir en tecnologías que ahorren en recursos y maximicen la productividad de un suelo cada vez más cálido.

El uso de la inteligencia artificial a actividades de predicción mejora la precisión y el conocimiento de las variables claves para la toma de decisiones. En este caso si la temperatura aumenta, es bastante probable que no haya lluvias en la costa ecuatoriana y haya que implementar plantas desalinizadoras para el consumo humano y agrícola, o paneles fotovoltaicos para generar la energía necesaria para la producción de alimentos. Estos elementos de política pública deben ser tenidos en cuenta para la sostenibilidad de la sociedad como tal. Estos desafíos nos llevan a pensar en próximos artículos donde se relacionen estas variables climáticas con su impacto en la sociedad, economía y organización humanas.

6. Referencias

- Aaishah-Radziah, Bt., Fadhillah, Y. y Ibrahim-Lawal, K. (2015). Temporal Dynamics of Trend in Relative Humidity with RH-SARIMA Model. *Modern Applied Science*, 9(3), 281-290. <http://dx.doi.org/10.5539/mas.v9n3p281>
- Abdul-Lateef, B. y Naheem, A. (2021). Sea level prediction using ARIMA, SVR and LSTM neural network: assessing the impact of ensemble Ocean-Atmospheric processes on models' accuracy. *Geomatics, Natural Hazards and Risk*, 12(1), 653-674. <https://doi.org/10.1080/19475705.2021.1887372>
- Afrifa-Yamoah, E. (2015). Application of ARIMA Models in Forecasting Monthly Average Surface Temperature of Brong Ahafo Region of Ghana. *International Journal of Statistics and Applications*, 5(5), 237-246. <https://doi.org/10.5923/j.statistics.20150505.08>
- Alaa-Ali, S. y Dmitry, K. (2023). Verification of MIKE 11-NAM Model for runoff modeling using ANN, FIS, and ARIMA methods in poorly studied basin. *E3S Web of Conferences*, 401, 1-10. <https://doi.org/10.1051/e3sconf/202340101035>
- Antoinette-Marie, R. y Sigrid, R. (2022). Using artificial intelligence models and degree-days method to estimate the heat consumption evolution of a building stock until 2050: A case study in a temperate climate of the Northern part of Europe. *Cleaner and Responsible Consumption*, 5, 100069. <https://doi.org/10.1016/j.clrc.2022.100069>

- Box, G. E., Jenkins, G. M., Reinsel, G. C. y Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Burnham, K. P. y Anderson, D. R. (2002). *Model Selection and Inference: A Practical Information-Theoretic Approach*. 2^a ed. Springer-Verlag. <http://dx.doi.org/10.1007/b97636>
- Coutinho, E., Madeira, J., Silva, R., Oliveira, E. y Delgado, A. (2023). Application of a Computational Hybrid Model to Estimate and Filling Gaps for Meteorological Time Series. *Revista Brasileira De Meteorologia*, 38, 1-19. <https://doi.org/10.1590/0102-778638220030>
- Dabral, P. y Murry, M. (2017). Modelling and forecasting of rainfall time series using SARIMA. *Environ. Proces*, 4, 399-419. <https://doi.org/10.1007/s40710-017-0226-y>
- Danandeh-Mehr, A., Ghadimi, S. y Marttila, H. (2022). A new evolutionary time series model for streamflow forecasting in boreal lake-river systems. *Theor Appl Climatol*, 148, 255-268. <https://doi.org/10.1007/s00704-022-03939-3>
- Dehbalaei, F., Azari, A. y Akhtari, A. (2023). Development of a linear-nonlinear hybrid special model to predict monthly runoff in a catchment area and evaluate its performance with novel machine learning methods. *Appl Water Sci*, 13, 118. <https://doi.org/10.1007/s13201-023-01917-2>
- Dimri, T., Ahmad, S. y Sharif, M. (2020). Time series analysis of climate variables using seasonal ARIMA approach. *J Earth Syst Sci.*, 129, 149. <https://doi.org/10.1007/s12040-020-01408-x>
- Farsi, M., Hosahalli, D., Manjunatha, R., Gad, I. y Ghoneim, O. (2020). Parallel genetic algorithms for optimizing the SARIMA model for better forecasting of the NCDC weather data. *Alexandria Engineering Journal*, 60(1), 1299-1316. <https://doi.org/10.1016/j.aej.2020.10.052>
- Fu, Y., Zhou, X., Sun, W. y Tang, Q. (2019). Hybrid model combining empirical mode decomposition, singular spectrum analysis, and least squares for satellite-derived sea-level anomaly prediction. *International Journal of Remote Sensing*, 40(20), 7817-7829. <https://doi.org/10.1080/01431161.2019.1606959>
- Fu, Y., Zhou, X., Zhou, D., Li, J. y Zhang, W. (2019). Estimation of sea level variability in the South China Sea from satellite altimetry and tide gauge data. *Advances in Space Research*, 68(2), 523-533. <https://doi.org/10.1016/j.asr.2019.07.001>
- Gokul-Krishnan, B., Mehta, V. y Rai, V. N. (2023). Stochastic modelling and forecasting of relative humidity and wind speed for different zones of Kerala. *MAUSAM*, 74(4), 1053-1064. <https://doi.org/10.54302/mausam.v74i4.5603>
- Guo, J., Zhang, L. y Guo, R. (2023). Relative humidity prediction with covariates and error correction based on SARIMA-EG-ECM model. *Model. Earth Syst. Environ*, 9, 4493-4505. <https://doi.org/10.1007/s40808-023-01738-x>
- Hosseinzadeh, P., Nassar, A., Boubrahimi, S. F. y Hamdi, S. M. (2023). ML-Based Streamflow Prediction in the Upper Colorado River Basin Using Climate Variables Time Series Data. *Hydrology*, 10(2), 29. <https://doi.org/10.3390/hydrology10020029>

- Hu, Y., Wang, N., Liu, S., Jiang, Q. y Zhang, N. (2021). Research on Application of Time Series Model and LSTM Model in Water Quality Prediction. *Journal of Chinese Computer Systems*, 42(8), 1569-1573.
- Kheimi, M., Almadani, M. y Zounemat-Kermani, M. (2023). Stochastic (S[ARIMA]), shallow (NARnet, NAR-GMDH, OS-ELM), and deep learning (LSTM, Stacked-LSTM, CNN-GRU) models, application to river flow forecasting. *Acta Geophys*, 72, 2679-2693. <https://doi.org/10.1007/s11600-023-01157-7>
- Kim, T., Shin, J.Y., Kim, H., Kim, S. y Heo, J.H. (2019). The Use of Large-Scale Climate Indices in Monthly Reservoir Inflow Forecasting and Its Application on Time Series and Artificial Intelligence Models. *Water*, 11(2), 374. <https://doi.org/10.3390/w11020374>
- Mishra, P., Al Khatib, A.M.G., Mohamad Alshaib, B., Binita, K., Tiwari, S., Singh, A. P., Yadav, S., Sharma, D. y Kumari, P. (2023). Forecasting Potato Production in Major South Asian Countries: a Comparative Study of Machine Learning and Time Series Models. *Potato Research*. <https://doi.org/10.1007/s11540-023-09683-z>
- Mishra, P., Mishra, P. C., Fatih, C., Vani, G. K., Lavrod, J. M., Jain, V., Dubey, A. y Choudhary, A. K. (2021). Modeling and forecasting of metrological factors using ARCH process under different errors distribution specification. *MAUSAM*, 72(2), 301-312. <https://doi.org/10.54302/mausam.v72i2.618>
- Nyatuame, M. y Agodzo, S. K. (2018). Stochastic ARIMA model for annual rainfall and maximum temperature forecasting over Tordzie watershed in Ghana. *Journal of Water and Land Development*, 37(4), 127-140. <https://doi.org/10.2478/jwld-2018-0032>
- Ortega-Ballesteros, A., Muñoz-Rodríguez, D., Aguilera-Ureña, M. J., De los Santos-Zarco, F. J. y Perea-Moreno, A. J. (2023). Application of Time-Controlled Critical Point in Pressure Reducing Valves: A Case Study in North Spain. *Applied Sciences*, 13(10), 5845. <https://doi.org/10.3390/app13105845>
- Pradeep, K., Arti-Choudhary, P., Rajendra, P. y Sudhir-Kumar, S. (2022). Multiple crop yield estimation and forecasting using MERRA-2 model, satellite-gauge and MODIS satellite data by time series and regression modelling approach. *Geocarto International*, 37(27), 16590-16619. <https://doi.org/10.1080/10106049.2022.2112301>
- Sabando-García, Á., Ugando-Peñate, M., Armas-Herrera, R., Higuerey-Gómez, Á., Espín Estrella, G. y Villalón-Peñate, A. (2022). Modelación econométrica y estocástica en los pronósticos de ventas de jengibre en Ecuador. *Ingeniería Investigación y Desarrollo*, 22(1), 25-43. <https://doi.org/10.19053/1900771X.v22.n1.2022.14453>
- Sagarika, R., Ajay-Kumar, T. y Prosun, B. (2023). A geospatial approach for understanding the spatio-temporal variability and projection of future trend in groundwater availability in the Tawi basin, Jammu, India. *Groundwater for Sustainable Development*, 21, 100912. <https://doi.org/10.1016/j.gsd.2023.100912>
- Shangguan, S., Lin, H., Wei, Y. y Tang, C. (2022). Spatiotemporal Modes Characteristics and SARIMA Prediction of Total Column Water Vapor over China during 2002–2022 Based on AIRS Dataset. *Atmosphere*, 13(6), 885. <https://doi.org/10.3390/atmos13060885>

- Swain, S., Mishra, S. K., Pandey, A. y Dayal, D. (2022). A Stochastic Model-Based Monthly Rainfall Prediction Over a Large River Basin. En B. Yadav, M. P. Mohanty, A. Pandey, V. P. Singh y R. D. Singh (Eds.), *Sustainability of Water Resources*, 116. Springer, Cham. https://doi.org/10.1007/978-3-031-13467-8_9
- Tang, C., Tong, Z., Wei, Y., Wu, X., Tian, X. y Yang, J. (2023). Time-Frequency Characteristics and SARIMA Forecasting of Atmospheric Water Vapor in East Asia. *Atmosphere*, 14(5), 899. <https://doi.org/10.3390/atmos14050899>
- Tang, C., Zhu, F., Wei, Y., Tian, X., Yang, J. y Zhao, F. (2023). Study of Time-Frequency Domain Characteristics of the Total Column Ozone in China Based on Wavelet Analysis. *Atmosphere*, 14(6), 941. <https://doi.org/10.3390/atmos14060941>
- Ugando-Peñate, M., Villalón-Peñate, A., Sabando-García, Á., Celi-Pinza, D., Pilay-Toala, F. y Racines-Cabrera, A. (2021). Modelización financiera aplicada en empresas del sector manufacturero en la ciudad de Santo Domingo de los Tsáchilas, Ecuador. *Revista De La Universidad Del Zulia*, 12(34), 8-28. <https://doi.org/10.46925//rdluz.34.02>
- Valipour, M. (2015). Long-term runoff study using SARIMA and ARIMA models in the United States. *Meteorol. Appl.*, 22, 592-598. <https://doi.org/10.1002/met.1491>
- Wang, H., Huang, J., Zhou, H., Zhao, L. y Yuan, Y. (2019). An Integrated Variational Mode Decomposition and ARIMA Model to Forecast Air Temperature. *Sustainability*, 11(15), 4018. <https://doi.org/10.3390/su11154018>
- Wu, J., Chen, X. y Chang, T. (2020). Correlations between hydrological drought and climate indices with respect to the impact of a large reservoir. *Theoretical and Applied Climatology*, 139, 727-739. <https://doi.org/10.1007/s00704-019-02991-w>
- Xiaowei, Z., Ping, Z., Liwei, Z. y Gaoyang, Z. (2022). A Comparison of Multivariate and Univariate Time Series Models Applied in Tree Sap Flux Analyses. *Forest Science*, 68(5-6), 473-486. <https://doi.org/10.1093/forsci/fxac027>
- Yang, R. y Xing, B. (2022). Evidence for Intensification in Meteorological Drought since the 1950s and Recent Dryness-Wetness Forecasting in China. *Atmosphere*, 13(5), 745. <https://doi.org/10.3390/atmos13050745>
- Yi-Hui, P., Hong-Bo, W., Jian-Jian, Z. y De-Yong, S. (2020). Analysis and Prediction of Hydraulic Support Load Based on Time Series Data Modeling. *Geofluids*, 1-15. <https://doi.org/10.1155/2020/8851475>
- Zolghadr-Asli, B., Enayati, M., Pourghasemi, H. R., Jahromi, M. N. y Tiefenbacher, J. (2021). A linear/non-linear hybrid time-series model to investigate the depletion of inland water bodies. *Environ Dev Sustain*, 23, 10727-10742. <https://doi.org/10.1007/s10668-020-01081-6>

CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

Conceptualización: Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; **Software:** Sabando-García, Ángel Ramón; **Validación:** Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; **Análisis formal:** Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; Tarazona Meza, Néstor Leopoldo; **Curación de datos:** Sabando-García, Ángel Ramón; Tarazona Meza, Néstor Leopoldo; **Redacción-Preparación del borrador original:** Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; Tarazona Meza, Néstor Leopoldo; Inga Llanez, Elvia Rosalía; D'Elia Di Michele, Pierina; **Redacción-Revisión y Edición:** Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; Inga Llanez, Elvia Rosalía; D'Elia Di Michele, Pierina; **Visualización:** Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; **Supervisión:** Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; **Administración de proyectos:** Sabando-García, Ángel Ramón; **Todos los/as autores/as han leído y aceptado la versión publicada del manuscrito:** Sabando-García, Ángel Ramón; Ugando Peñate, Mikel; Higuerey Gómez, Angel Alexander; Armas Herrera, Reinaldo; Tarazona Meza, Néstor Leopoldo; D'Elia Di Michele, Pierina; Inga Llanez, Elvia Rosalía.

Financiación: Esta investigación no recibió financiamiento externo.

Conflicto de intereses: No existe conflicto de intereses.

AUTOR/ES:

Ángel Ramón Sabando García

Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD), Ecuador.

Magíster en Estadística; Gerencia Educativa e Ingeniería Agrícola. Ejerce como docente investigador de la Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD) de Ecuador y es miembro del Grupo de investigación Planning, Innovation and Financial Modeling Applied. Durante su trayectoria como investigador ha publicado artículos en el área de las matemática y estadística, modelación financiera, gerencia, agrícola y finanzas ética en revistas nacionales e internacionales.

arsabando@pucesd.edu.ec

Índice H: 5

Orcid ID: <https://orcid.org/0000-0001-5438-9590>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=57968587400>

Google Scholar: <https://scholar.google.es/citations?user=x71g7mUAAAAJ&hl=es&oi=ao>

ResearchGate: <https://www.researchgate.net/profile/Angel-Ramon-Garcia>

Mikel Ugando Peñate

Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD), Ecuador.

Doctor en Economía por la Universidad Santiago de Compostela, España y Master en Contabilidad y finanzas. Ejerce como docente investigador de la Pontificia Universidad Católica del Ecuador- Sede Santo Domingo (PUCESD) de Ecuador y coordina el Grupo de investigación Planning, Innovation and Financial Modeling Applied. Actualmente coordina proyectos a nivel nacional referentes a las finanzas éticas y valores cristianos, así como a la incidencia del cambio climático en la producción agrícola.

mugandop@pucesd.edu.ec

Índice H: 9

Orcid ID: <https://orcid.org/0000-0002-3021-0717>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=56362645600>

Google Scholar: <https://scholar.google.es/citations?user=cyUmuwEAAAAJ&hl=es>

ResearchGate: <https://www.researchgate.net/profile/Mikel-Ugando-Penate-3/stats>

Reinaldo Armas Herrera

Universidad Técnica Particular de Loja (UTPL), Ecuador.

PhD. en Economía por la Universidad de Las Palmas de Gran Canarias (ULPG), España. Magíster en Finanzas y Economista por la ULPGC. Actualmente es docente investigador del Departamento de Ciencias Empresariales, Universidad Técnica Particular de Loja (UTPL), Loja, Ecuador. En su rol como investigador se ha especializado en las áreas de finanzas, capital intelectual, educación universitaria y finanzas éticas, publicando artículos en revistas nacionales e internacionales de gran impacto.

ahreinaldo@utpl.edu.ec

Índice H: 10

Orcid ID: <https://orcid.org/0000-0002-3477-5838>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=56320272800>

Google Scholar: <https://acortar.link/DAAZ6F>

ResearchGate: <https://www.researchgate.net/profile/Reinaldo-Armas-Herrera>

Ángel Alexander Higuerey Gómez

Universidad Técnica Particular de Loja (UTPL), Ecuador.

Doctor en Economía por la Universidad de Las Palmas de Gran Canarias, España. Magister y Especialista en Derecho Tributario por la Universidad Santa María, Venezuela. Licenciado en Administración por la Universidad de Oriente, Venezuela. Actualmente se desempeña como profesor investigador de la UTPL, Ecuador. Investigador reconocido perteneciente al Instituto Experimental de Investigaciones Humanísticas, Económicas y Sociales (IEXIHES) de la Universidad de Los Andes, Venezuela y el grupo de investigación GESCONT de la UTPL.

aahiguerey@utpl.edu.ec

Índice H: 13

Orcid ID: <https://orcid.org/0000-0003-0031-8898>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=11239132700>

Google Scholar: <https://scholar.google.es/citations?user=nEziZ1EAAAAJ&hl=es&oi=sra>

ResearchGate: <https://www.researchgate.net/profile/Angel-Higuerey>

Academia.edu: <https://independent.academia.edu/AHiguerey>

Néstor Leopoldo Tarazona Meza

Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López, Ecuador.

Docente de la escuela superior politécnica agropecuaria de Manabi, de la carrera de ingeniería agrícola, asignatura meteorología... Máster en Ingeniería Agrícola.

nestor.tarazona@espam.edu.ec

Orcid ID: <https://orcid.org/0000-0002-2145-6475>

Pierina D'Elia Di Michele

Universidad Técnica Particular de Loja (UTPL), Ecuador.

Dra. PhD en Educación por la Universidad Rafael María Baralt, Venezuela, Licenciada en Educación Integral, Magister en Ciencias de la Educación y Magister en Educación Robinsoniana por la UNESR, Venezuela. Actualmente es docente investigadora en el Departamento de Filosofía, Artes y Humanidades de la UTPL, Ecuador. Promotora de la Línea de Investigación: ACPTS-UNESR y miembro del grupo de investigación EDUFAM-UTPL contribuyendo a la línea de Valores Cristianos.

pdelia@utpl.edu.ec

Orcid ID: <https://orcid.org/0000-0001-7763-7577>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=58114350800>

ResearchGate: <https://www.researchgate.net/profile/Pierina-D-Elia-Di-Michele>

Elvia Rosalía Inga Llanez

Universidad Técnica Particular de Loja (UTPL), Ecuador.

Magister en Contabilidad y Auditoría en la Universidad de Santiago de Chile, posee un Diplomado en Auditoría de Gestión en la Universidad de Santiago de Chile, y es Ingeniero Comercial y Licenciado en Administración de la Universidad Católica de Cuenca. Actualmente es docente investigadora en el Departamento de Ciencias Empresariales de la UTPL y miembro del grupo de investigación GESCONT.

eringa1@utpl.edu.ec

Orcid ID: <https://orcid.org/0000-0002-9853-4363>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=57195315563>

ResearchGate: <https://www.researchgate.net/profile/Elvia-Inga-Llanez>