Revista de Climatología

Vol. 20 (2020): 15-28 ISSN 1578-8768

©Copyright de los autores de cada artículo. Se permite su reproducción y difusión por cualquier medio, siempre que se haga sin interés económico y respetando su integridad

Determinación de las épocas lluviosas y secas en la ciudad de Chachapoyas para el periodo de 2014-2018

Jesús Rascón*, Wildor Gosgot Angeles, Manuel Oliva, Lenin Quiñones Huatangari y Miguel Ángel Barrena Gurbillón

Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva, Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas. Calle Higos Hurco Nº342-350-356, Calle Universitaria Nº304, Chachapoyas 01001, Perú. *e-mail: <jesus.rascon@untrm.edu.pe>*

(Recibido: 19-May-2020. Publicado: 24-Jul-2020)

Resumen

El estudio de las precipitaciones, permite definir e implementar estrategias en diferentes zonas. El objetivo de esta investigación fue conocer la variabilidad de las precipitaciones en la ciudad de Chachapoyas. Para ello, se contó con dos bases de datos, la del Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva (INDES-CES) y la del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Se hizo un análisis exploratorio de los datos, obteniendo datos atípicos, relacionados con los vacíos en la base del INDES-CES. Se aplicó una regresión lineal, para poder completar los vacíos en la data del INDES-CES. Con las bases de datos completas, se realizó un análisis de series temporales y predicciones con un modelo auto regresivo de media móvil (ARMAR). El completado de datos, fue un éxito, con un 98.7 % de ajuste. Se puede concluir que hay dos patrones muy marcados relacionados con las épocas lluviosas (noviembre a abril) y secas (mayo a octubre).

Palabras clave: Datos atípicos, estacionalidad, Andes, Amazonas.

Statistical determination of wet and dry seasons in the city of Chachapoyas for the period 2014-2018

Abstract

The study of rainfall, allows to define and implement strategies in different areas. The objective of this research was to know the variability of rainfall in the city of Chachapoyas. For this purpose, two databases were used, one from the Research Institute for the Sustainable Development of Ceja de Selva (INDES-CES) and the other from the National Meteorology and Hydrology Service of Peru (SENAMHI). An exploratory analysis of the data was made, obtaining atypical data, related to the gaps in the INDES-CES database. A linear regression was applied in order to fill in the gaps in the INDES-CES data. With the complete databases, a time series analysis and predictions were made with a moving average auto-regression model (ARMAR). The completion of the data was a success, with a 98.7% adjustment. It can be concluded that there are two very marked patterns related to the rainy (November to April) and dry (May to October) seasons.

Key words: *Atypical data, seasonality, Andes, Amazonas.*

1. Introducción

Varios factores influyen en la variación climática, al ser producto de diferentes eventos meteorológicos dados en diferentes escalas espaciales y temporales (días, meses, estaciones, años). La estacionalidad dada por periodos húmedos y secos, es uno de los fenómenos climáticos que más impacto causa en actividades como, por ejemplo, la generación de energía hidroeléctrica (Luce *et al.*, 2016; Olsson *et al.*, 2017).

Tener un buen conocimiento de la distribución espacial y temporal de la precipitación es fundamental para una correcta caracterización de la respuesta hidrológica en una cuenca de drenaje. Aun así, son

escasos los estudios sobre variabilidad de precipitación en cuencas de montaña en Sudamérica, y especialmente en los Andes (Sarricolea-Espinoza y Romero-Aravena, 2015). Se trata de cuencas de gran interés para la correcta gestión de los recursos hídricos, al ser cabeceras de cuenca y generar la mayor parte de la aportación de las grandes cuencas. Algunos estudios han puesto de manifiesto la relación entre la distribución espacial de la lluvia y la altimetría (Llasat *et al.*, 2016), mostrando que existe un gradiente hipsométrico positivo sólo hasta cierta altura, llamado punto crítico de inversión, a partir de la cual el gradiente disminuye. En la cuenca de Reynolds Creek de unos 234 km^2, situada en el estado de Idaho de los Estados Unidos, Johnson y Hanson (1995) calcularon un gradiente de 0.6 mm/m entre 1200 y 2000 m.s.n.m. Sin embargo, otros estudios han mostrado que la altitud no es el único factor explicativo de la variabilidad de la precipitación, ya que en muchos casos también influyen la pendiente, la exposición, la orientación e incluso la distancia al mar (Blanchet *et al.*, 2018; Pereira *et al.*, 2016). Spreen (1947), demostró que estos factores explicaban el 88 % de variabilidad de la precipitación en Colorado y que, de entre ellos, la altitud solo explicaba el 30 %. Por otro lado, está Japón o Corea, donde por la cercanía al mar, el efecto Foehn es importante, a mayor exposición a los vientos dominantes, la precipitación registrada es también mayor (Tang *et al.*, 2002; Um *et al.*, 2016). En Nueva Zelanda, se registró un gradiente espacial de precipitación de +5,3 % por km en los 20 km que separan la franja costera de la cordillera de los Alpes Neozelandeses (Sattler *et al.*, 2016). Otro estudio realizado en el Himalaya, también puso de manifiesto un gradiente altitudinal y de orientación (Basistha *et al.*, 2008). La heterogeneidad espacial de la precipitación también se ve influenciada por el tipo del evento lluvioso, como es el caso de las precipitaciones de tipo conectivo.

Es por ello que, un buen análisis climático necesita que los datos meteorológicos existentes sean una serie temporal de datos continuos, homogéneos y que abarquen el máximo intervalo temporal posible (Sun *et al.*, 2018). Una gran parte de esas series de datos tienen lagunas de información debido a diferentes motivos, como la interrupción de las lecturas, los fallos en los instrumentos de medida, errores asociados a cambios en las condiciones de medición, errores de transcripción, entre otros (Feng *et al.*, 2004). Es por ello, que estos análisis presentan el inconveniente inicial de plantearse el relleno de esos huecos y he aquí el gran problema de cómo se deben rellenar esos vacíos (Sahin y Cigizoglu, 2010). Esto es importante, porque con el completado se van a generar nuevos valores para las series que no han sido medidos por ningún instrumento, y si esos valores calculados no son realistas, las conclusiones de cualquier análisis que se realice sobre esos datos serán erróneas (Teegavarapu y Chandramouli, 2005).

Existen diferentes métodos o técnicas para el completado de datos faltantes, sin embargo existe poca bibliografía especializada en este tema para el área de la Meteorología o Climatología (Di Piazza *et al.*, 2011). Los vacíos de datos en un registro meteorológico se pueden rellenar o completar mediante técnicas que combinen el conocimiento de la evolución de cada variable meteorológica (Suhaila *et al.*, 2008), de sus relaciones con las registradas en el entorno, y de su relación con otras variables registradas bajo las mismas condiciones (Gul *et al.*, 1998). Por tanto, se puede hacer uso del conocimiento físico de la variable y sus relaciones, así como de técnicas de interpolación y estadísticas (Hutchinson, 1995; Joyce *et al.*, 2004; Teegavarapu y Chandramouli, 2005).

Los valles y cuencas altoandinas de Chachapoyas, se caracterizan por el gran desarrollo de la ganadería y la agricultura, así como un potencial para la generación de energía hidráulica, para sustentar el gran crecimiento de la ciudad de Chachapoyas, que ha sido exponencial en la última década. Es por ello que la disponibilidad hídrica es realmente importante para estas actividades (Padilla, 2016). Viendo estas razones, es necesario analizar estadísticamente los patrones de precipitación pluvial. Sin embargo en la zona de Chachapoyas, muchas estaciones meteorológicas cuentan con grandes vacíos de información. Por tanto, para el estudio de las precipitaciones, se realiza un completado de datos de las estaciones existentes, y con estos se elaboran series temporales, tanto para determinar los patrones de estacionalidad, como para realizar predicciones. Esto permite contribuir al conocimiento meteorológico de la zona, y así se podrán tomar las medidas necesarias para una gestión ideal de actividades como la agricultura y la energética.

2. Material y métodos

2.1. Zona de estudio

La provincia de Chachapoyas se localiza en el sur del departamento de Amazonas, en el Noreste de Perú. Limita al este con la provincia de Rodríguez de Mendoza y el departamento de San Martín, al sur con el departamento de La Libertad, al oeste con la provincia de Luya y el departamento de Cajamarca, y al norte con la provincia de Bongará y el departamento de San Martín (figura 1). Se caracteriza por tener un rango altitudinal entre los 2000 y 3000 m.s.n.m., con temperaturas suaves a lo largo del año (Mendoza-Mestanza *et al.*, 2018; Oliva *et al.*, 2017).

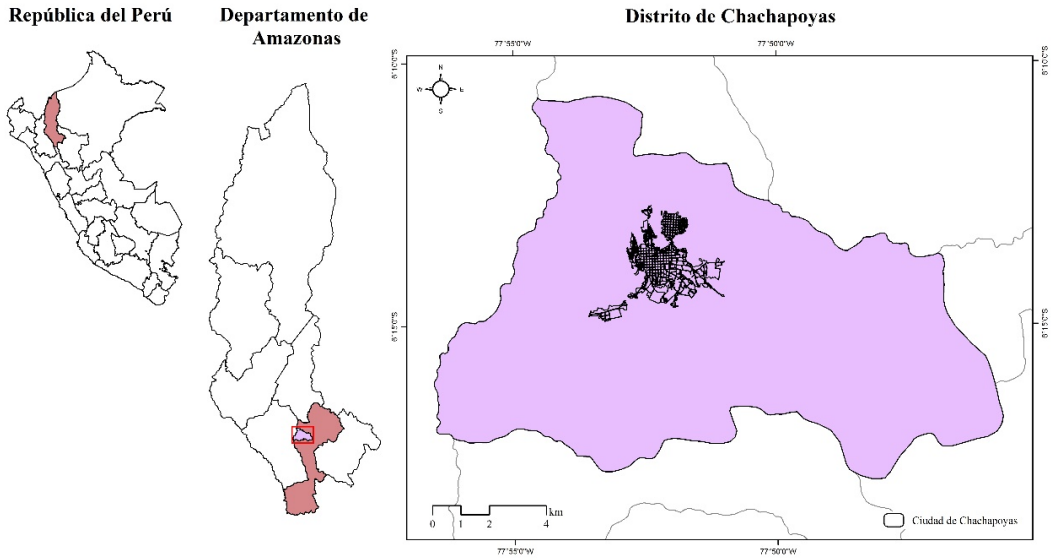

Fig. 1: Ubicación de la Ciudad de Chachapoyas

2.2. Estaciones meteorológicas

La información utilizada es parte del registro de datos meteorológicos monitoreados por las dos estaciones meteorológicas que existen dentro de la misma ciudad de Chachapoyas, una del Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva (INDES-CES), y la otra del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Los datos registrados fueron desde enero de 2014 a diciembre de 2018, ya que la estación del INDES-CES empezó su funcionamiento en 2014.

2.3. Determinación de datos atípicos

Con el propósito de identificar datos atípicos en los datos de precipitaciones en este periodo y su normalidad, se utilizaron dos tipos de gráficos, un diagrama de cajas y bigotes, así como un histograma. Se ha realizado usando el paquete estadístico R (R Core Team, 2019).

2.4. Relleno de datos con el método de regresión lineal

El método de regresión lineal requiere series para el análisis, se decidió utilizar dos series completas, una de cada estación, sin los valores de cero y los datos ordenados. Previamente, se han realizado las pruebas de correlación para determinar si los datos a usar son adecuados para realizar la regresión lineal. Tras la regresión lineal, se realizó una ANOVA para comprobar si la regresión es válida y los gráficos del cumplimiento de los supuestos del modelo. Todos estos análisis, se ha realizado por cada estación. Todo ello usando el paquete estadístico R (R Core Team, 2019).

2.5. Determinación de patrones de precipitaciones con series temporales

Se determinó la estacionalidad de las precipitaciones en el periodo 2014-2018, con el análisis de series temporales. Este análisis, se realizó para las dos bases de datos. Se ha realizado usando el paquete estadístico R (R Core Team, 2019).

2.6. Predicciones de precipitaciones mediante el método ARMAR

Gracias a las series temporales obtenidas se pueden hacer predicciones, para ello, se usó el método ARMAR, a través del paquete estadístico R (R Core Team, 2019).

3. Resultados y discusiones

3.1. Determinación de datos atípicos

Del análisis de los diagramas se observó que toda la data de la estación del INDES, presenta varios valores atípicos, sobre todo en el año 2015, con valores cercanos a los 75 mm de precipitaciones (figura 2). Los datos no se distribuyen de forma normal, siendo más típico los datos del primer cuartil, esto pasa en todos los años del periodo de estudio.

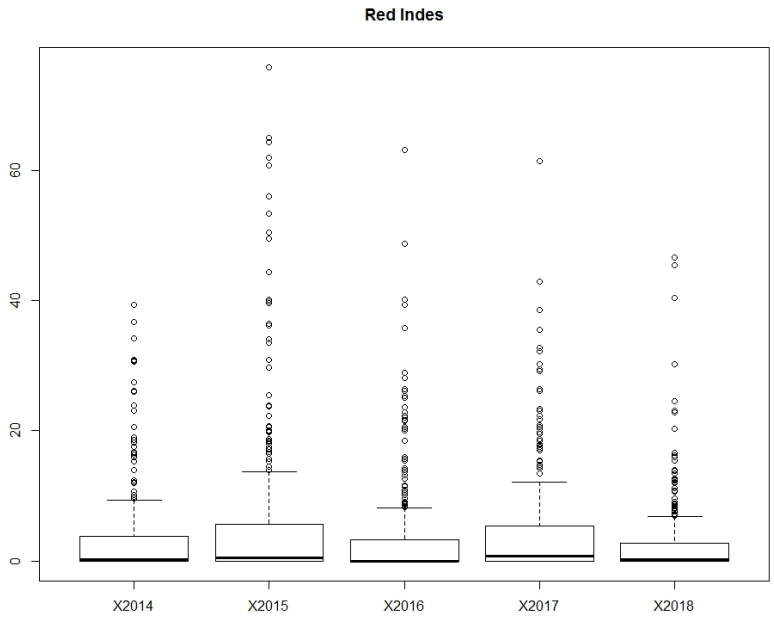

Fig. 2: Gráfico de cajas y bigotes de los datos de la estación del INDES.

Del análisis de los diagramas se observó que toda la data de la estación del SENAMHI, presenta varios valores atípicos, sobre todo en el año 2018, con valores cercanos a los 75 mm de precipitaciones (figura 3). Los datos no se distribuyen de forma normal, y tienen un comportamiento igual que la estación del INDES.

Al comparar todos los datos, se puede observar que los años 2015 y 2018 fueron los que registraron un valor atípico más alto. Sin embargo, eso no confirma que sean los años más lluviosos, para ello es necesario ver las series temporales y la cantidad de precipitaciones por año (Villegas *et al.*, 2019). El uso de diagramas de cajas y bigotes, es muy útil en estos casos. Permite resumir de forma gráfica y concisa la distribución de los datos, así como sus características esenciales, como la mediana, el rango entre

cuartiles, el sesgo y la presencia de valores atípicos (Helsel y Hirsch, 2002; Wadoux *et al.*, 2017). Los valores atípicos detectados, no fueron eliminados de la serie, al no encontrar razones objetivas para su descarte, lo cual es común en estos casos (Lujano-Laura y Felipe-Obando, 2015).

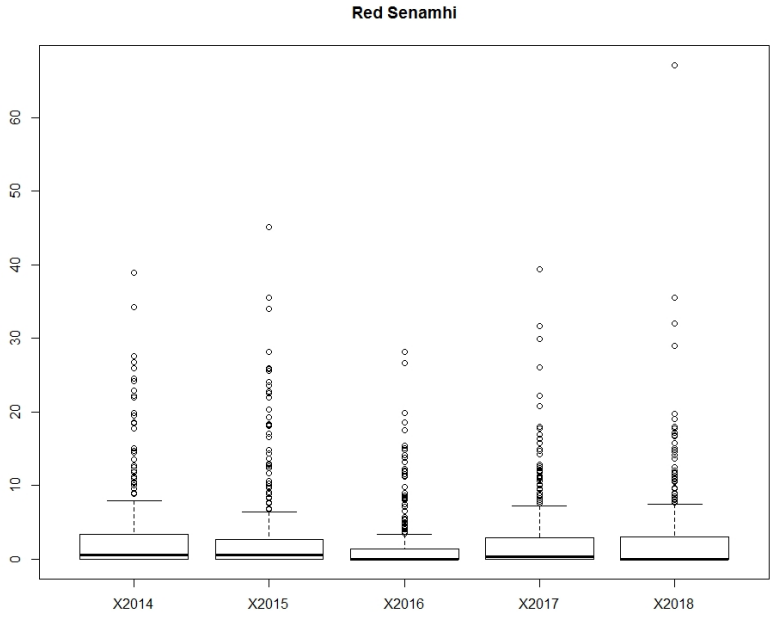

Fig. 3: Gráfico de cajas y bigotes de los datos de la estación del SENAMHI.

3.2. Relleno de datos con método de regresión lineal

Los datos de las dos estaciones (INDES y SENAMHI), tienen una gran correlación entre ellos (r = 0.99), por tanto, los datos de las series, por ahora, son idóneos para realizar el método de regresión lineal (Luna-Romero y Lavado-Casimiro, 2015), aunque lo ideal es que haya más cantidad de estaciones cercanas para que este tipo de análisis tenga más fuerza como recomiendan varios autores (Contreras *et al.*, 2018; Pereira *et al.*, 2016; Sahin y Cigizoglu, 2010). En nuestro caso, la densidad de estaciones es baja, solo dos estaciones para toda la zona del distrito de Chachapoyas, algo muy común en las zonas Andinas (Domínguez-Castro *et al.*, 2018).

El modelo de regresión lineal, tuvo un 98,7 % de ajuste, lo que indica un porcentaje muy alto de que el modelo sea lo más aproximado a la realidad, para ambos casos (tabla 1, figuras 4 a 8). Resultados parecidos se obtuvieron en el río Ambi, en Ecuador, aunque en este caso se tenían cuatro estaciones meteorológicas (Carrera-Villacrés *et al.*, 2016). Por otro lado, que la regresión sea tan alta, se debe principalmente a la gran cercanía entre las estaciones (Carlo *et al.*, 2010; Olsson *et al.*, 2017; Wen *et al.*, 2018).

Tabla 1: Parámetros estadísticos de las rectas de regresión de los datos de las estaciones. (p-valor<0.001, *: altamente significativos).

Xi	Yi	r	r2	Error	p-valor
SENAMHI	INDES	0.987*	0.987*	1.121	<2.2e-16*
INDES	SENAMHI	0.987*	0.987*	0.773	<2.2e-16*

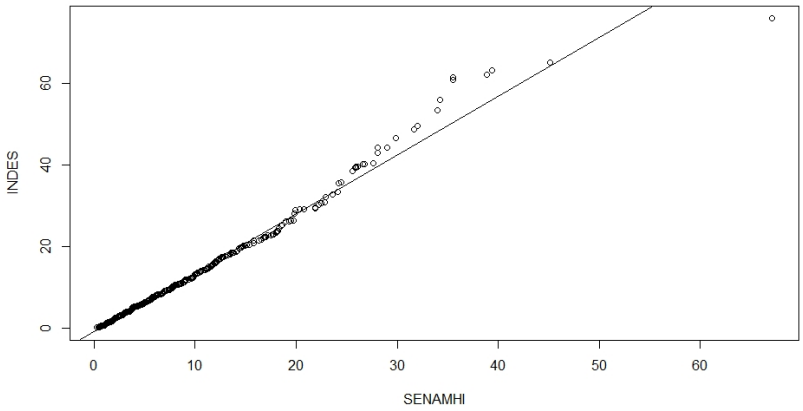

Fig. 4: Diagrama de dispersión y recta de regresión, con las cuales se realizaron los pronósticos de datos faltantes en la estación del INDES (Y=-0.668335+1.441333X).

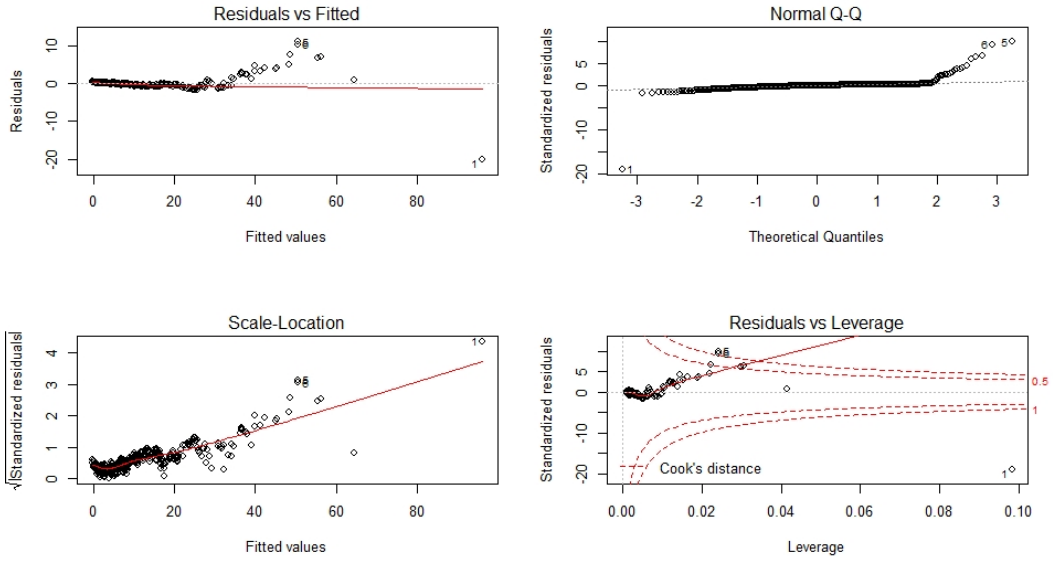

Fig. 5: Gráficos del cumplimiento de los supuestos del modelo INDES vs SENAMHI.

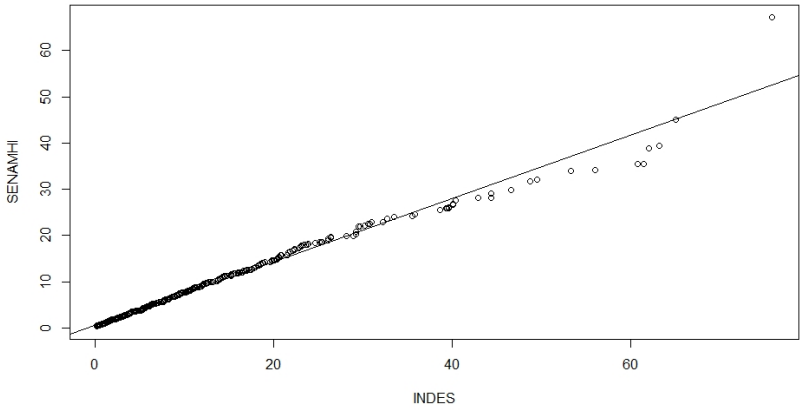

Fig. 6: Diagrama de dispersión y recta de regresión, con las cuales se realizaron los pronósticos de datos faltantes en la estación del SENAMHI.(Y=0.526563+0.684723X).

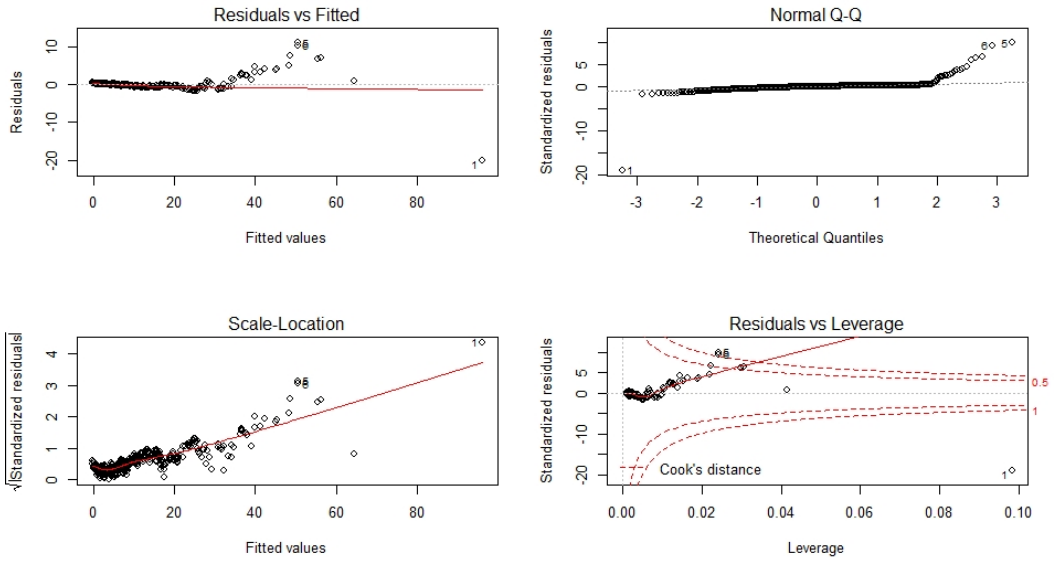

Fig. 7: Gráficos del cumplimiento de los supuestos del modelo SENAMHI vs INDES.

Todos los gráficos de los modelos cumplen con el supuesto de aleatoriedad (primer gráfico de las figuras 5 y 7), con el supuesto de normalidad (segundo gráfico de las figuras 5 y 7), con el supuesto de homoscedasticidad (tercer gráfico de las figuras 5 y 7), y por último ningún dato influye negativamente en el modelo de regresión lineal (cuarto gráfico de las figuras 5 y 7).

En cualquier caso, la regresión lineal en los registros de ambas estaciones es alta, con un coeficiente de correlación altamente significativo. Para comprobar la calidad de los ajustes, al verificar los supuestos de normalidad, se observó que en ambos casos muestran una asimetría hacia la derecha, lo que sugiere que los datos no se ajustan a una distribución Normal. Al mismo tiempo, el coeficiente de determinación observado promedio es del 98,6 %, lo que ratifica la bondad del ajuste. Esto corrobora que el uso de la regresión lineal para el completado de vacíos en los datos es un método adecuado y por tanto aceptado (Herrera-Oliva *et al.*, 2017; Sattler *et al.*, 2016).

3.3. Determinación de variabilidad de precipitaciones con series temporales

Con el análisis de series temporales, se pueden comprobar los patrones de estacionalidad y la variabilidad de las precipitaciones en los últimos años (Nielsen *et al.*, 2014; Um *et al.*, 2016). Sin embargo, se aprecian más los patrones de estacionalidad en la estación del SENAMHI que en la del INDES (figuras 8 y 9).

Observando las series temporales, podemos establecer que existen patrones muy marcados de estacionalidad, la cual determina las épocas lluviosas y secas de la zona de Chachapoyas. Por tanto, la época lluviosa corresponde con los meses de noviembre a abril, con un pico en los meses de enero a marzo. Asimismo, la época seca se da en los meses de mayo a octubre, con un valle de junio a agosto (figuras 10 y 11). Por tanto, las series temporales son un análisis idóneo para determinar los patrones de estacionalidad de cualquier parámetro climatológico, como se comprueba en la gran mayoría de estudios realizados en Perú (Olsson *et al.*, 2017), Ecuador (Campozano *et al.*, 2016), Chile (González-Reyes *et al.*, 2017), Brasil (Noriega *et al.*, 2009), Colombia (Ventosilla *et al.*, 2013), China (Zhao *et al.*, 2012) o España (Pérez y Sanz, 2000). También hay que añadir, que en Sudamérica es de gran importancia este tipo de análisis, para conocer mejor el Fenómeno El Niño (FEN) (Lavado-Casimiro y Espinoza, 2014; Thielen *et al.*, 2016).

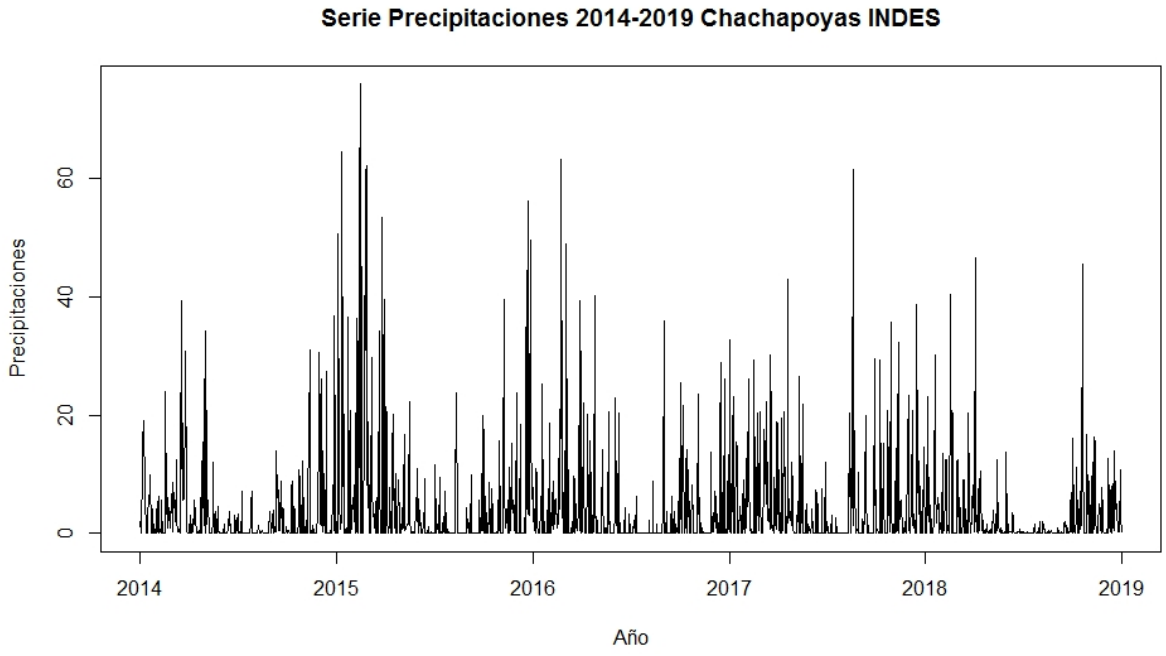

Fig. 8: Serie temporal de la estación del INDES para el periodo de 2014 a 2018, en la ciudad de Chachapoyas.

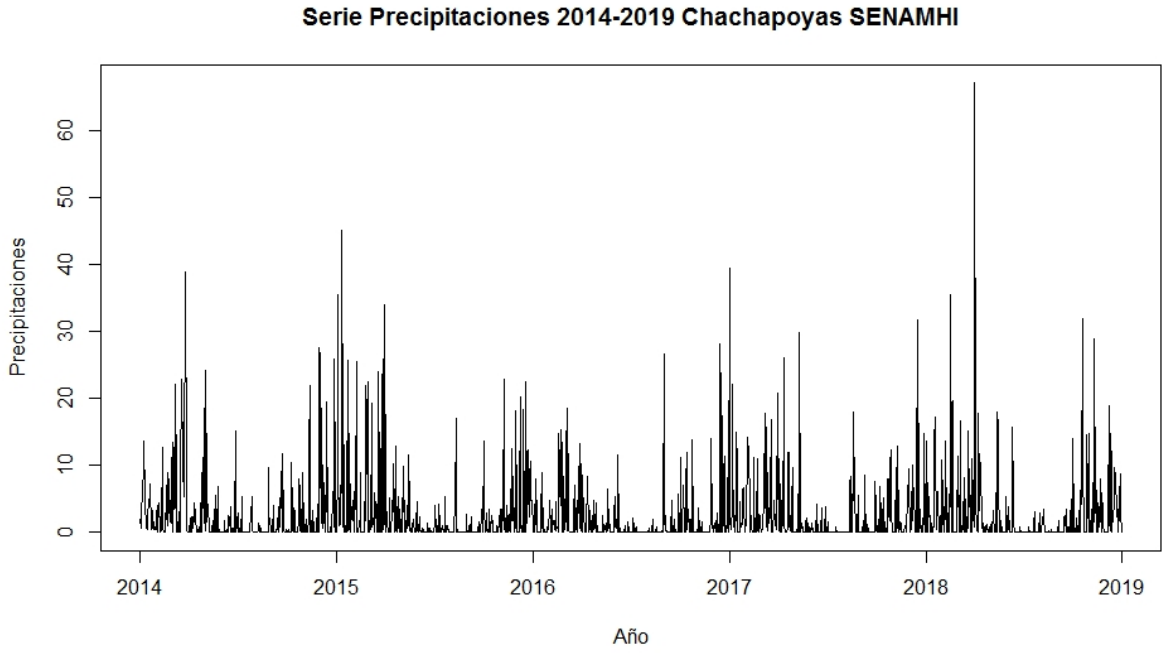

Fig. 9: Serie temporal de la estación del SENAMHI para el periodo de 2014 a 2018, en la ciudad de Chachapoyas.

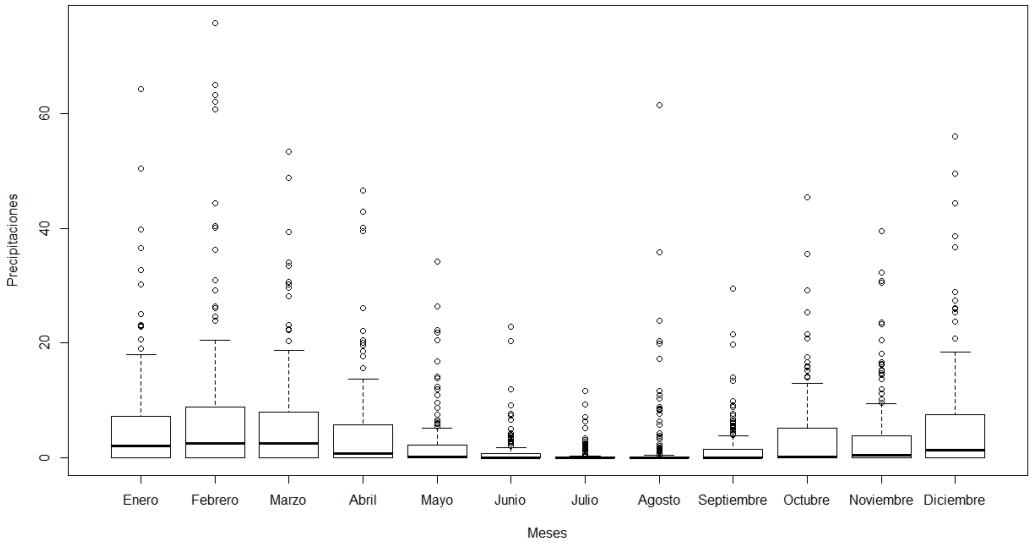

Fig. 10: Box-plots mensuales de la precipitación de la estación INDES para el periodo de 2014 a 2018, en la ciudad de Chachapoyas.

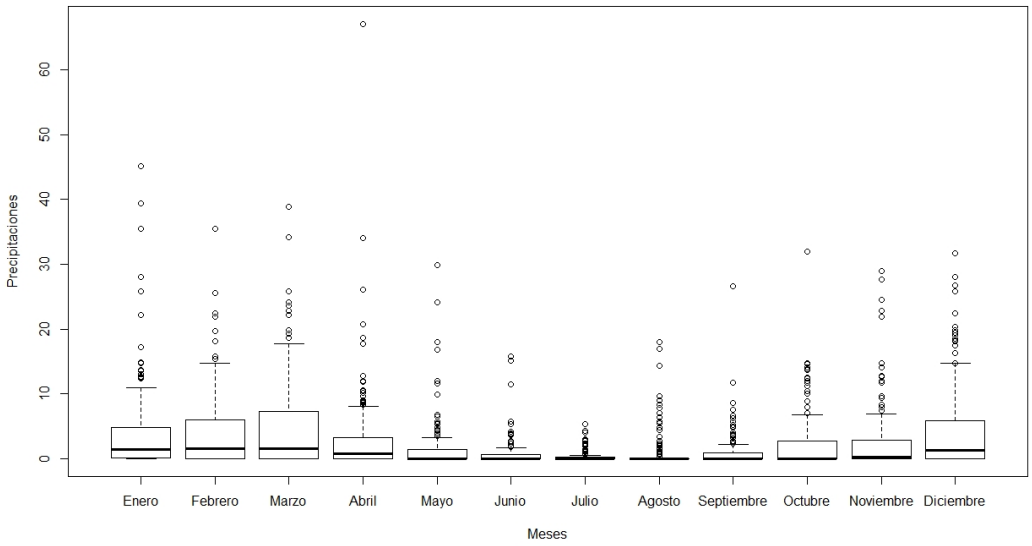

Fig. 11: Box-plots mensuales de la precipitación de la estación SENAMHI para el periodo de 2014 a 2018, en la ciudad de Chachapoyas.

3.4. Predicciones de precipitaciones mediante el método ARMAR

Como se menciona anteriormente, las series temporales obtenidas indican que son modelos mixtos, ya que tienen una fase estacional y otra estacionaria. Es por ello que las predicciones que se obtienen son del tipo (0,1,1)(1,1,0) (figuras 12 a 15).

Las predicciones con el método ARMAR, nos permiten ver cómo será la variabilidad de la lluvia en los próximos 40 días. No obstante, ambas predicciones tienen una gran incertidumbre, por lo que su uso práctico no es aconsejado. Por ello, sería necesario seguir recolectando datos para tener mejores predicciones, ya que las series temporales y sus usos para predicciones, suelen hacer uso de series de

datos de 30 años hasta 70 años de datos históricos (Mazza *et al.*, 2015; Santos *et al.*, 2015; Wadoux *et al.*, 2017).

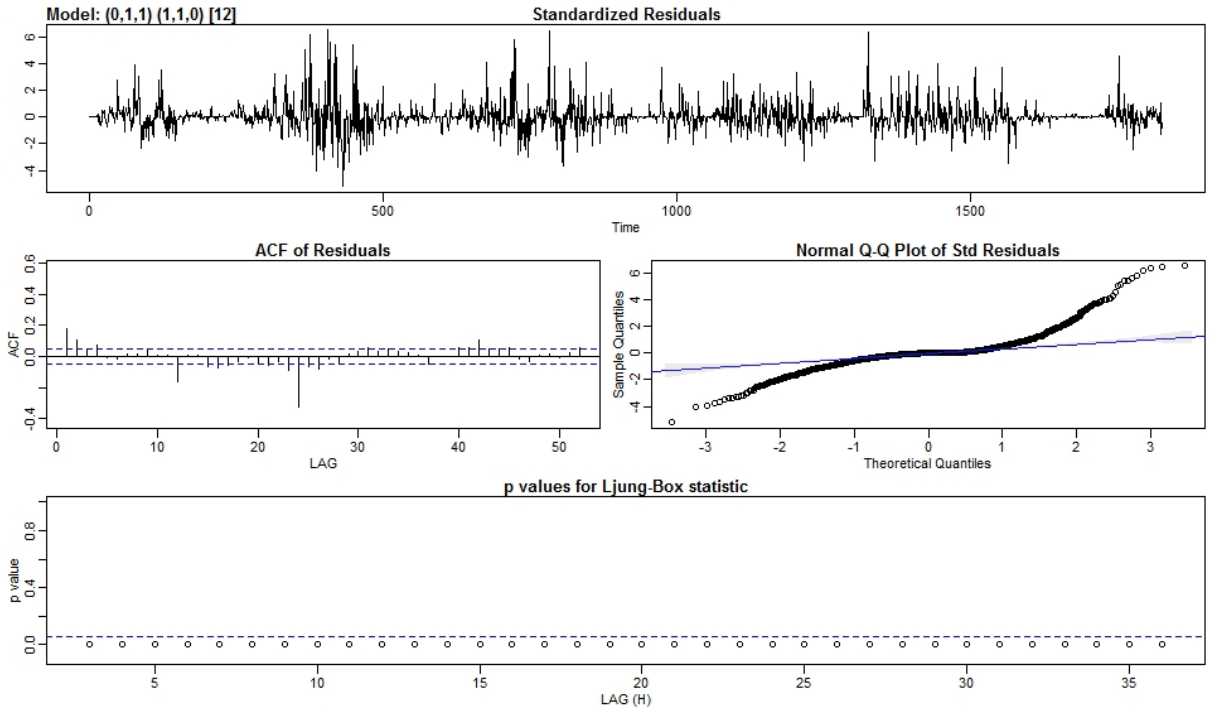

Fig. 12: Modelo Estación INDES (0,1,1)(1,1,0)

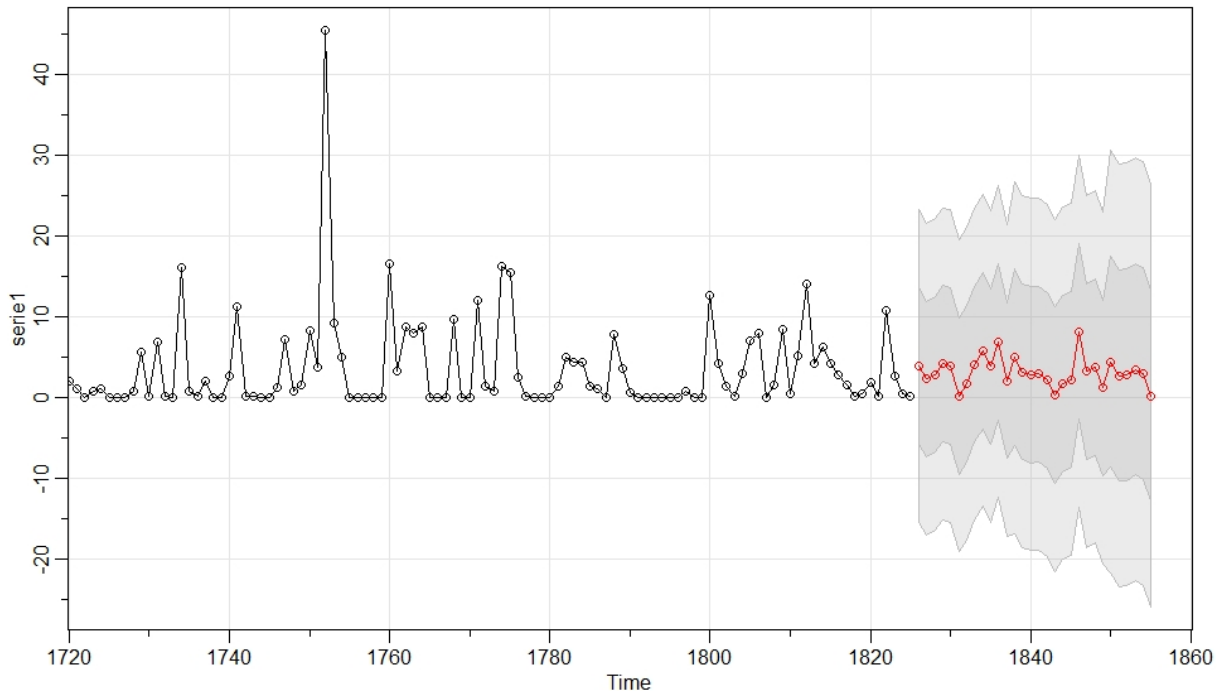

Fig. 13: Predicción de datos para la estación INDES.

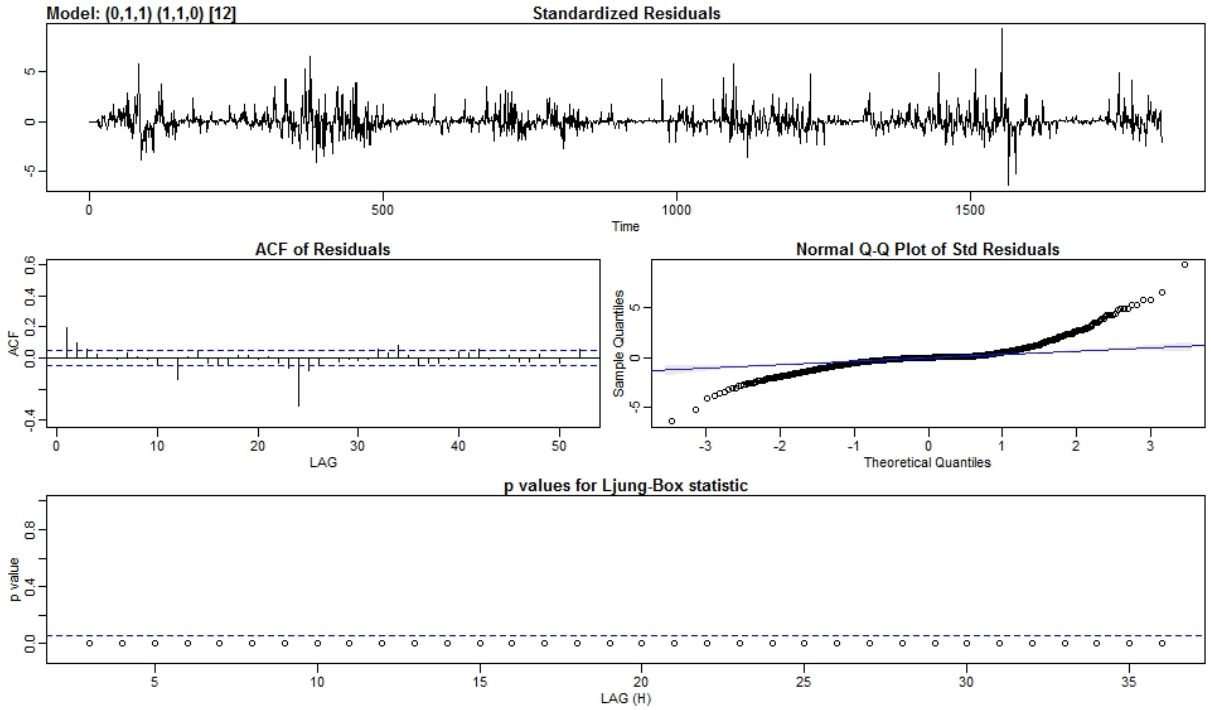

Fig. 14: Modelo Estación SENAMHI (0,1,1)(1,1,0)

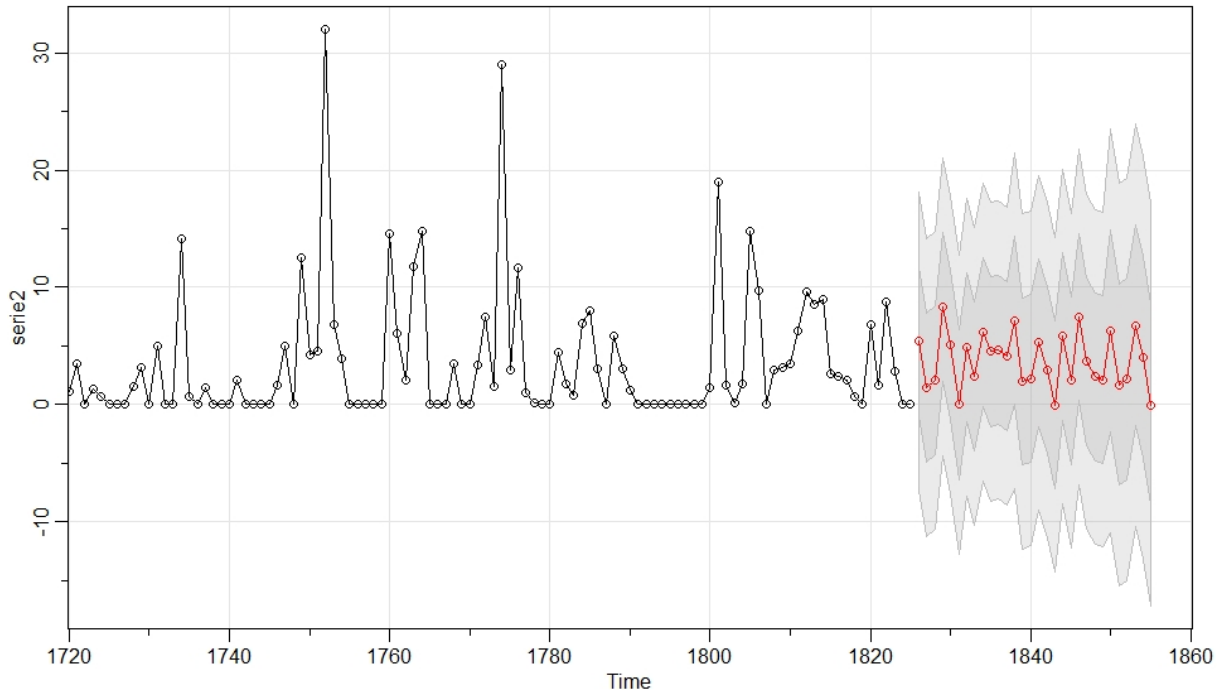

Fig. 15: Predicción de datos para la estación SENAMHI.

4. Conclusiones

La ciudad de Chachapoyas, al ser una ciudad andina, tiene una gran estacionalidad en las precipitaciones. Por ello, presenta una gran cantidad de valores atípicos, los cuales son necesarios para conocer su realidad. Sin embargo, hay un problema en este tipo de regiones, la baja cantidad de datos fiables, debido a la baja densidad de estaciones meteorológicas, dos para el caso del distrito y ciudad de Chachapoyas.

El completado de datos para Chachapoyas, aunque usando solo dos estaciones meteorológicas, ha sido un éxito, ya que, el completado de datos tuvo un ajuste del 99 % para el modelo planteado, con lo que se puede decir que la regresión lineal es adecuada para la evaluación realizada. Por otro lado, tras aplicar las series temporales, se puede concluir que queda comprobada la estacionalidad de las precipitaciones, teniendo dos épocas muy marcadas. La época lluviosa en los meses de noviembre a abril, con un pico en los meses de enero a marzo. Y la época seca en los meses de mayo a octubre, con una disminución de precipitación en los meses de junio a agosto. Esto es de gran ayuda para futuras investigaciones en la zona, ya que por fin se ha demostrado dicha estacionalidad de forma estadística. Por último, tras realizar las predicciones, estas se acercan a la realidad y son muy útiles para otras investigaciones o planes de gestión. Aunque hay que mencionar que cuando la data tenga más tiempo, mínimo unos 20 años, mejor serán las predicciones.

5. Bibliografía

Basistha A, Arya DS, Goel NK (2008): Spatial distribution of rainfall in Indian Himalayas-A case study of Uttarakhand Region. *Water. Resour. Manag.*, 22:1325-1346, DOI: 10.1007/s11269-007-9228-2.

Blanchet J, Paquet E, Vaittinada P, Penot (2018): Mapping rainfall hazard based on rain gauge data: an objective cross-validation framework for model selection. *Hydrol. Earth Syst. Sci.*, 23:829-849, DOI: 10.5194/hess-23-829-2019.

Campozano L, Célleri R, Trachte K, Bendix J, Samaniego E (2016): Rainfall and cloud dynamics in the Andes: A Southern Ecuador case study. *Adv. Meteorol.*, 2016:1-15, DOI: 10.1155/2016/3192765.

Carlo J, Villar E, Ronchail J, Lavado W, Cochonneau G, Oliveira EDE, Pombosa R, Vauchel P, Guyot JL (2010): Variabilidad espacio-temporal de las lluvias en la Cuenca Amazónica y su relación con la variabilidad hidrológica regional. Un enfoque particular sobre la Región Andina. *Rev. Peru. Geo-Atmosférica RPGA.*, 130:99-130.

Carrera-Villacrés DV, Guevara-García PV, Tamayo-Bacacela LC, Balarezo-Aguilar AL, Narváez-Rivera CA, Morcho-López DR (2016): Relleno de series anuales de datos meteorológicos mediante métodos estadísticos en la zona costera e interandina del Ecuador, y cálculo de la precipitación media. *IDESIA*, 34:81-90.

Contreras J, Ballari D, de Bruin S, Samaniego E (2018): Rainfall monitoring network design using conditioned Latin Hypercube Sampling and satellite precipitation estimates: An application in the ungauged Ecuadorian Amazon. *Int. J. Climatol.*, 39:2209-2226, DOI: 10.1002/joc.5946.

Di Piazza A, Lo Conti F, Noto LV, Viola F, La Loggia G (2011): Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. *Int. J. Appl. Earth. Obs.* 13:396-408, DOI: 10.1016/j.jag.2011.01.005.

Domínguez-Castro F, Vicente-Serrano SM, López-Moreno JI, Correa K, Ávalos G, Azorin-Molina C, El Kenawy A, Tomas-Burguera M, Navarro-Serrano F, Peña-Gallardo M, Gimeno L, Nieto R (2018): Mapping seasonal and annual extreme precipitation over the Peruvian Andes. *Int. J. Climatol.*, 38:5459-5475, DOI: 10.1002/joc.5739.

Feng S, Hu Q, Qian W (2004): Quality control of daily meteorological data in China, 1951-2000: A new dataset. *Int. J. Climatol.*, 24:853-870, DOI: 10.1002/joc.1047.

González-Reyes Á, Aravena JC, Muñoz AA, Soto-Rogel P, Aguilera-Betti I, Toledo-Guerrero I (2017): Variabilidad de la precipitación en la ciudad de Punta Arenas, Chile, desde principios del siglo XX. *An. Inst. Patagon.*, 45:31-44, DOI: 10.4067/s0718-686x2017000100031.

Gul MS, Muneer T, Kambezidis HD (1998): Models for obtaining solar radiation from other meteorological data. *Solar Energy*, 64:99-108, DOI: 10.1016/S0038-092X(98)00048-6.

Helsel DR, Hirsch RM (2002). *Statistical methods in water resources*. USGS, Washington DC.

Herrera-Oliva CS, Campos-Gaytán JR, Carrillo-González FM (2017): Estimación de datos faltantes de precipitación por el método de regresión lineal: Caso de estudio Cuenca Guadalupe, Baja California, México. *Investigación y Ciencia*, 71:34-44.

Hutchinson MF (1995): Stochastic space-time weather models from ground-based data. *Agr. Forest. Meteorol.*, 73:237-264.

Johnson GL, Hanson CL (1995): Topographic and atmospheric influences on precipitation variability over a mountainous watershed. *J. Appl. Meteorol. Clim.*, 34:68-87, DOI: 10.1175/1520-0450-34.1.68.

Joyce RJ, Janowiak JE, Arkin PA, Xie P (2004): CMORPH: A method that produces global precipitation estimates from passive microwave and infraestación data at high spatial and temporal resolution. *J. Hydrometeorol,* 5:487-503. DOI: 10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2.

Lavado-Casimiro W, Espinoza JC (2014): Impactos del Niño y la Niña en las lluvias del Perú (1965-2007). *Rev. Bras. Meteorol.*, 29:171-182, DOI: 10.1590/S0102-77862014000200003.

Llasat MC, Marcos R, Turco M, Gilabert J, Llasat-Botija M (2016): Trends in flash flood events versus convective precipitation in the Mediterranean region: The case of Catalonia. *J. Hydrol.*, 541:24-37, DOI: 10.1016/j.jhydrol.2016.05.040.

Luce CH, Vose JM, Pederson N, Campbell J, Millar C, Kormos P, Woods R (2016): Contributing factors for drought in United States forest ecosystems under projected future climates and their uncertainty. *Forest. Ecol. Management*, 380:299-308, DOI: 10.1016/j.foreco.2016.05.020.

Lujano-Laura E, Felipe-Obando OG (2015): Análisis de frecuencia regional de las precipitaciones máximas diarias en la región hidrográfica del Titicaca. *Rev. Investig. Altoandin.*, 17:53-64, DOI: 10.18271/ria.2015.78.

Luna-Romero E, Lavado-Casimiro W (2015): Evaluación de métodos hidrológicos para la completación de datos faltantes de precipitación en estaciones de la cuenca Jetepeque, Perú. *Rev. tecnol.*, 28:42-52.

Mazza A, Antonini A, Melani S, Ortolani A (2015): Recalibration of cumulative rainfall estimates by weather radar over a large area. *J. Appl. Remote Sens.*, 9:1-20, DOI: 10.1117/1.jrs.9.095993.

Mendoza-Mestanza J, Rituay-Yoplac JM, Barrena-Gurbillón, MA (2018): Eficiencia térmica de un calentador solar doméstico de agua hecho con botellas plásticas, Chachapoyas-Amazonas, 2014. *Revista de Investigación Científica UNTRM: Ciencias Naturales e Ingeniería*, 1:34-37.

Nielsen JE, Thorndahl S, Rasmussen MR (2014): A numerical method to generate high temporal resolution precipitation time series by combining weather radar measurements with a nowcast model. *Atmos. Res.*, 138:1-12, DOI: 10.1016/j.atmosres.2013.10.015.

Noriega CE, Muniz K, Flores-Montes MJ, Macêdo SJ, Araujo M, Feitosa FA, Lacerda SR (2009): Series temporales de variables hidrobiológicas en un estuario tropical (Brasil). *Rev. Biol. Mar. Oceanog.*, 44:93-108, DOI: 10.4067/s0718-19572009000100009.

Oliva M, Neri-Chávez JC, Huamán-Huamán E, Oyarce-Tafur SK, Collazos-Silva R (2017): Efecto de la aplicación de abonos orgánicos sobre el rendimiento de repollo Corazón de Buey (Brassica oleracea) en Chachapoyas, Amazonas. *Rev. de investig. agroproducción sustentable*, 1:20-27, DOI: 10.25127/aps.20173.370.

Olsson T, Kämäräinen M, Santos D, Seitola T, Tuomenvirta H, Haavisto R, Lavado-Casimiro W (2017): Downscaling climate projections for the Peruvian coastal Chancay-Huaral Basin to support river discharge modeling with WEAP. *J. Hydrol. Reg. Stud.*, 13:26-42, DOI: 10.1016/j.ejrh.2017.05.011.

Padilla AMG (2016): Demanda hídrica y calidad de agua de uso agrícola de la cuenca del río Jequetepeque, Perú. *Rev. Rebiol.*, 35:5-18.

Pereira P, Oliva M, Misiune I (2016): Spatial interpolation of precipitation indexes in Sierra Nevada (Spain): comparing the performance of some interpolation methods. *Theor. Appl. Climatol.*, 126:683-698, DOI: 10.1007/s00704-015-1606-8

Pérez ME, Sanz JJ (2000): Distribuciones estadísticas ajustadas a las series temporales de totales anuales de precipitación en España: aspectos geográficos. *Geographicalia*, 38:11-29.

R Core Team (2019): *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna.

Sahin S, Cigizoglu HK (2010): Homogeneity analysis of Turkish meteorological data set. *Hydrol. Process.*, 24:981-992, DOI: 10.1002/hyp.7534.

Santos J, Norte F, Moreiras S, Araneo D, Simonelli S (2015): Predicción de episodios de precipitación que ocasionan aludes en el area montañosa del Noroeste de la Provincia de Mendoza, Argentina. *Geoacta*, 40:65-75.

Sarricolea-Espinoza P, Romero-Aravena H (2015): Variabilidad y cambios climáticos observados y esperados en el altiplano del norte de Chile. *Rev. geogr. Norte Gd.*, 62:169-183, DOI: 10.4067/S0718-34022015000300010.

Sattler K, Anderson B, Norton K, Mackintosh A, De Róiste M (2016): Estimating permafrost distribution in the Maritime Southern Alps, New Zealand, based on climatic conditions at Rock Glacier Sites. *Front. Earth. Sci.*, 4:1-17. DOI: 10.3389/feart.2016.00004.

Spreen WC (1947): A determination of the effect of topography upon precipitation. *EOS*, 28:285-290, DOI: 10.1029/TR028i002p00285.

Suhaila J, Sayang MD, Jemain AA (2008): Revised spatial weighting methods for estimation of missing rainfall data. *Asia-Pacific J. Atmos. Sci.*, 44:93-104.

Sun Q, Miao C, Duan Q, Ashouri H, Sorooshian S, Hsu KL (2018): A review of global precipitation data sets: Data sources, estimation, and intercomparisons. *Rev. Geophy.*, 56:79-107, DOI: 10.1002/2017RG000574.

Tang C, Shindo S, Machida I (2002): Topographical effects on the distributions of rainfall and 18O distributions: a case in Miyake Island, Japan. *Hydrol. Process.*, 12:673-682, DOI: 10.1002/(sici)1099-1085(19980330)12:4<673::AID-HYP608>3.0.CO;2-Y

Teegavarapu RSV, Chandramouli V (2005): Improved weighting methods, deterministic and stochastic data-driven models for estimation of missing precipitation records. *J. Hydrol.*, 312:191-206, DOI: 10.1016/j.jhydrol.2005.02.015

Thielen D, Cevallos J, Erazo T, Zurita, IS, Figueroa J, Matute N, Quintero JI, Puche ML (2016): Dinámica espacio-temporal de las precipitaciones durante el evento de El Niño 97 / 98 en la cuenca de Río Portoviejo , Manabí , costa ecuatoriana del Pacífico. *Rev. Climatol.*, 16:35-50.

Um MJ, Heo JH, Kim NW (2016): Spatio-temporal variations of precipitation considering the orographic effects on Jeju Island. *Atmos. Res.*, 181:236-249, DOI: 10.1016/j.atmosres.2016.07.007.

Ventosilla P, Almanza R, Suárez-Acosta C, Chauca J, Rúa-Uribe GL (2013): Modelado del efecto de la variabilidad climática local sobre la transmisión de dengue en Medellín (Colombia) mediante análisis de series temporales. *Biomédica*, 33:142-152, DOI: 10.7705/biomedica.v33i0.1444.

Villegas D, Rivas Y, Pérez Y, Villegas S, Milla M (2019): Evaluación de observaciones atípicas en datos climatológicos y en modelos lineales simulados. *Rev. Climatol.*, 19:67-73.

Wadoux AMJC, Brus DJ, Rico-Ramirez MA, Heuvelink GBM (2017): Sampling design optimisation for rainfall pestacióniction using a non-stationary geostatistical model. *Adv. Water. Resour.*, 107:126-138, DOI: 10.1016/j.advwatres.2017.06.005-

Wen X, Gao X, Su L, Fan Q, Peng W (2018): Analysis of influencing factors and characteristics of small hydropower generation. *Proceedings of 2017 9th International Conference On Modelling, Identification and Control*, ICMIC, Kunming, China, IEEE, pp. 658-662. DOI: 10.1109/ICMIC.2017.8321537

Zhao Q, Liu S, Deng L, Dong S, Yang J, Wang C (2012): The effects of dam construction and precipitation variability on hydrologic alteration in the Lancang River Basin of southwest China. *Stoch. Env. Res. Risk A.*, 26:993-1011, DOI: 10.1007/s00477-012-0583-z