



PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE

ESCUELA DE INGENIERIA

**PRECIPITACIÓN ESTACIONAL EN COSTA RICA
Y SU RELACIÓN CON LAS ANOMALÍAS
TÉRMICAS Y DE PRESIÓN EN LOS OCÉANOS
PACÍFICO Y ATLÁNTICO**

MARTÍN RODOLFO MORALES MORA

Tesis para optar al grado de

Magíster en Ciencias de la Ingeniería

Profesor supervisor:

JORGE GIRONÁS LEÓN

Santiago de Chile, enero, 2021

© 2021, Martín Rodolfo Morales Mora



PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE

ESCUELA DE INGENIERIA

**PRECIPITACIÓN ESTACIONAL EN COSTA RICA
Y SU RELACIÓN CON LAS ANOMALÍAS
TÉRMICAS Y DE PRESIÓN EN LOS OCÉANOS
PACÍFICO Y ATLÁNTICO**

MARTÍN RODOLFO MORALES MORA

Tesis presentada a la comisión integrada por los profesores:

JORGE GIRONÁS

FRANCISCO SUÁREZ

CHRISTOPHER AIKEN

RICARDO GIESEN

Para completar las exigencias del grado de
Magíster en ciencias de la ingeniería

Santiago de Chile, enero, 2021

“porque veo al final de mi rudo camino que yo fui el arquitecto de mi propio destino;”

-Amado Nervo

AGRADECIMIENTOS

Quiero agradecer a todas las personas que de una u otra manera me ayudaron con la realización de este trabajo. En especial, quiero agradecerle a Trihana, por todos sus consejos, su apoyo, su fortaleza y paciencia a lo largo de todo este proceso. También le agradezco especialmente a mis papás, por su ayuda incondicional en todo momento y sus incontables oraciones.

Al profesor Christopher Aiken, por su buena disposición para ayudarme y guiarme en todo momento, así como su empatía durante el magíster. A los profesores Jorge Gironás y Francisco Suárez, por su apoyo y ayuda para la culminación de este trabajo.

A mis compañeros del Departamento de Hidráulica y Ambiental, los cuales hicieron del proceso del magíster una experiencia enriquecedora, en particular a aquellos que su amistad trascendió más allá de la parte académica.

Al Consejo Nacional para Investigaciones Científicas y Tecnológicas (CONICIT) y al Ministerio de Ciencia, Tecnología y Telecomunicaciones (MICITT) de Costa Rica, que me permitieron por medio del financiamiento otorgado, no solo realizar mis estudios de postgrado, sino también desarrollar la presente investigación. También le agradezco al Instituto Meteorológico de Costa Rica (IMN) por la información de precipitación facilitada para la elaboración del trabajo.

ÍNDICE GENERAL

1	INTRODUCCIÓN.....	1
1.1	Contexto	1
1.2	Problema de investigación.....	5
1.3	Hipótesis de investigación.....	6
1.4	Objetivos	7
2	DATOS Y MÉTODOS.....	8
2.1	Características de la zona de estudio.....	8
2.2	Datos.....	11
2.2.1	Precipitación.....	11
2.2.2	Variables explicativas	12
2.3	Metodología.....	14
2.3.1	Funciones ortogonales empíricas y componentes principales	14
2.3.2	Modelos de regresión lineal	17
2.3.3	Construcción de los modelos de regresión.....	19
2.3.4	Evaluación de la habilidad de pronóstico	23
3	PREDICTIBILIDAD DE LA PRECIPITACIÓN ESTACIONAL	29
3.1	Campo de precipitación.....	29
3.2	Campos de las variables explicativas: SST y SLP	35
3.3	Correlaciones temporales entre la precipitación y las variables explicativas....	37
3.4	Predictibilidad de la precipitación estacional	41
3.4.1	Modo caribe	43
3.4.2	Modo Pacífico	48

4	PRONÓSTICO DE LA PRECIPITACIÓN.....	54
4.1	Habilidad real de pronóstico.....	54
4.2	Análisis de los modelos de regresión para pronóstico	60
4.3	Precipitación del mes de mayo en la vertiente pacífica.....	67
4.3.1	Pronóstico de la precipitación de mayo en el pacífico.....	69
4.4	Precipitación de los meses de julio, agosto y septiembre en la vertiente caribe	73
4.4.1	Modelo Julio-Caribe.....	74
4.4.2	Modelo Agosto-Caribe.....	75
4.4.3	Modelo Septiembre-Caribe	77
4.4.4	Pronóstico de la precipitación de julio-agosto-septiembre en la vertiente caribe	80
5	CONCLUSIONES.....	88
	BIBLIOGRAFIA	93
	ANEXOS	98
	A1. Información de estaciones utilizadas.....	99
	A2. Tercer EOF del campo de la precipitación en Costa Rica.....	100
	A3. Reconstrucción de las series de precipitación	101
	A4. Correlación temporal de la precipitación con índices oceánicos y atmosféricos	105
	A5. Cuantificación de la habilidad de pronóstico por medio del RAE y Sesgo.....	107
	A6. Análisis de varianza de los modelos de regresión	109

ÍNDICE DE TABLAS

Tabla 2-1: Clasificación de los valores del SPI	27
Tabla 3-1: Máximas correlaciones lineales del modo caribe para cada mes	39
Tabla 3-2: Máximas correlaciones lineales del modo pacífico para cada mes	39
Tabla 3-3: Predictores de los modelos de regresión generados para el modo caribe.....	47
Tabla 3-4: Predictores de los modelos de regresión generados para el modo pacífico....	50
Tabla 4-1: RSR de los modelos de regresión y los modelos de referencia del modo pacífico	57
Tabla 4-2: RSR de los modelos de regresión y los modelos de referencia del modo caribe	58
Tabla 4-3: Desempeño del modelo Mayo-Pacífico a partir de las métricas continuas	61
Tabla 4-4: Desempeño de los modelos para el modo caribe a partir de las métricas continuas	61
Tabla 4-5: Significancia estadística de los coeficientes del modelo Mayo-Pacífico	62
Tabla 4-6: Significancia estadística de los coeficientes del modelo Julio-Caribe	62
Tabla 4-7: Significancia estadística de los coeficientes del modelo Agosto-Caribe	63
Tabla 4-8: Significancia estadística de los coeficientes del modelo Septiembre-Caribe.	63
Tabla 4-9: Pronóstico categórico con los valores de SPI para mayo en la vertiente pacífica	71
Tabla 4-10: Pronóstico categórico con los valores de SPI para julio en la vertiente caribe	81
Tabla 4-11: Pronóstico categórico con los valores de SPI para agosto en la vertiente caribe	83
Tabla 4-12: Pronóstico categórico con los valores de SPI para septiembre en la vertiente caribe	85
Tabla 4-13: Probabilidad de obtención de forma aleatoria el número de aciertos de los modelos	87

ÍNDICE DE FIGURAS

Figura 2-1: Mapa del relieve de Costa Rica.....	9
Figura 2-2: Variación estacional de la precipitación según la vertiente	11
Figura 2-3: Distribución espacial de las estaciones meteorológicas consideradas	12
Figura 2-4: Ubicación de estaciones usadas para los períodos de construcción-validación y testeo de los modelos de regresión.....	24
Figura 3-1: Comportamiento espacial de los primeros dos modos de precipitación	30
Figura 3-2: Varianza explicada acumulada según la cantidad de EOF considerados.....	33
Figura 3-3: Variación espacial del R^2 entre las series de precipitación observadas y las series reconstruidas a partir de los primeros dos EOF	34
Figura 3-4: Comportamiento espacial del primer EOF de SST	36
Figura 3-5: Comportamiento espacial de los primeros cuatro EOF de SLP	37
Figura 3-6: Variabilidad de la habilidad predictiva según el mes y el desfase considerado para el modo caribe	44
Figura 3-7: Comportamiento espacial del segundo EOF de la SST.....	46
Figura 3-8: Variabilidad de la habilidad predictiva según el mes y el desfase considerado para el modo pacífico	48
Figura 3-9: Variación temporal de la correlación entre el modo pacífico y SST1	53
Figura 3-10: Variación temporal de la correlación entre el modo caribe y SST1	53
Figura 4-1: Separación de estaciones para pronóstico según el modo de precipitación ..	55
Figura 4-2: Comparación del RSR entre los modelos de regresión para el modo pacífico y los modelos de referencia.....	57
Figura 4-3: Comparación del RSR entre los modelos de regresión para el modo caribe y los modelos de referencia.....	58
Figura 4-4: Comparación de la precipitación registrada en septiembre en las estaciones del caribe en el período 2016 – 2019	59
Figura 4-5: Comportamiento de los residuos versus las estimaciones para cada modelo de pronóstico	65
Figura 4-6: Evaluación de correlación en los residuos	66

Figura 4-7: EOF combinado a partir de los EOF de SST contemplados en el modelo Mayo-Pacífico	68
Figura 4-8: EOF de SLP contemplado en el modelo Mayo-Pacífico.....	68
Figura 4-9: Distribución espacial del RSR según el pronóstico de la precipitación de mayo en el pacífico	73
Figura 4-10: EOF combinado a partir de los EOF de SST contemplados en el modelo Julio-Caribe	75
Figura 4-11: EOF combinado a partir de los EOF de SST contemplados en el modelo Agosto-Caribe	77
Figura 4-12: EOF combinado a partir de los EOF de SST contemplados en el modelo Septiembre-Caribe.....	79
Figura 4-13: EOF de SLP contemplado en el modelo Septiembre-Caribe	79
Figura 4-14: Distribución espacial del RSR según el pronóstico de la precipitación de julio en el caribe	82
Figura 4-15: Distribución espacial del RSR según el pronóstico de la precipitación de agosto en el caribe.....	84
Figura 4-16: Distribución espacial del RSR según el pronóstico de la precipitación de septiembre en el caribe.....	86

RESUMEN

En zonas de clima tropical, la precipitación estacional presenta una fuerte relación con el comportamiento de fenómenos oceánicos y atmosféricos de gran escala. En Centroamérica se ha estudiado principalmente la relación y la capacidad de pronóstico que tiene la temperatura superficial del mar (SST) en la precipitación estacional. Costa Rica, sin embargo, presenta un comportamiento que difiere al encontrado a nivel regional, especialmente en la vertiente caribe del país. En este estudio se analiza la relación que tiene la precipitación estacional de Costa Rica, no solo con la SST sino también con la presión a nivel del mar (SLP), con el objetivo de evaluar la mejora en la habilidad de pronóstico al considerar ambas variables predictoras. A partir de un análisis de componente principales, tanto de los campos de precipitación como de los campos de SST y SLP, se construyeron modelos de regresión lineal, diferenciados para cada mes, por medio de los cuales se analizó el efecto que tienen las variables predictoras en la precipitación estacional de Costa Rica. Como resultado se obtuvo que la precipitación estacional en Costa Rica es explicada principalmente por los dos primeros componentes principales, siendo el primero el que describe la precipitación en la vertiente caribe (modo caribe) y el segundo el que representa la precipitación en la vertiente pacífica y región central del país (modo pacífico). El modo caribe fue el que presentó la mayor predictibilidad, en especial para el tercer trimestre del año, para el cual se obtuvieron modelos con ventanas de pronóstico de entre 2 y 5 meses. Para el modo pacífico, el mes de mayo, correspondiente al primer mes de la época lluviosa, presentó la mayor predictibilidad, mostrando que es posible realizar pronósticos con una antelación de hasta 6 meses, siendo esta una mejoría en términos de pronósticos operacionales.

Palabras claves: precipitación estacional, pronóstico, Costa Rica, regresión lineal, componentes principales, temperatura superficial del mar, presión a nivel del mar, anomalías.

ABSTRACT

In tropical regions, seasonal precipitation is strongly related to large-scale oceanographic and atmospheric systems. In Central America, the effect and forecasting ability of sea surface temperature (SST) on seasonal precipitation has been extensively examined. Costa Rica, however, has shown a different behavior from the rest of the region, particularly in its Caribbean slope. This study investigates the relation that seasonal precipitation in Costa Rica has, not only with SST but also with sea level pressure (SLP), with the aim of evaluating the improvement in forecasting ability when both variables are considered as predictors. Based on a principal component analysis of both the precipitation field, and SST and SLP fields, linear regression models, differentiated for each month, were developed to evaluate the effect of predictors on seasonal precipitation of Costa Rica. As a result, it was determined that seasonal precipitation can be explained by the first two principal components: the first one describing precipitation on the Caribbean slope (Caribbean Mode) and the second one representing the variability on both the Pacific slope and the central region of the country (Pacific Mode). The Caribbean Mode shows the highest predictability, especially on the third quarter of the year, for which forecast windows of 2 - 5 months were obtained for the regression models. As for the Pacific Mode, May was the month with highest predictability, with a model able to forecast precipitations up to 6 months in advance. Thus, the above shows an improvement in terms of operational forecasting, especially since May is the first month of the rainy season on the Pacific slope.

Keywords: seasonal precipitation, forecast, Costa Rica, linear regression, principal components, sea surface temperatures, sea level pressure, anomalies.

1 INTRODUCCIÓN

1.1 Contexto

La variación estacional e interanual de la precipitación tiene considerables implicaciones en diferentes actividades relacionadas con los recursos hídricos, tales como prevención de sequías e inundaciones, agricultura, silvicultura y diseño y operación de estructuras hidráulicas (Waylen et al., 1996).

En varias regiones tropicales, los valores previos a la temporada de lluvias de variables como la presión media a nivel del mar, los vientos zonales y meridionales en superficie y las anomalías de la temperatura superficial del mar, muestran fuertes relaciones con índices de precipitación estacional (Ward & Folland, 1991, Adnan et al., 2017). Dichas relaciones se presentan también con patrones atmosféricos de gran escala y con las características de la superficie terrestre. No obstante, muchas de las relaciones analizadas se cree que son el resultado de la influencia de la temperatura superficial del mar, tanto a nivel regional como global, en la atmósfera tropical (Mutai et al., 1998).

En las últimas dos décadas, en la región de América Central y la cuenca del mar Caribe, se ha estudiado el efecto que tienen los fenómenos atmosféricos de gran escala sobre el clima regional, específicamente sobre las características de la precipitación estacional (Enfield y Alfaro, 1999; Giannini et al., 2000; Giannini et al., 2001; Alfaro, 2002; Alfaro, 2007, Maldonado et al., 2013; Maldonado et al., 2017). En general, la mayoría de los estudios realizados a nivel regional presentan una metodología basada en análisis estadísticos empíricos, por medio del uso de modelos lineales, siendo utilizado principalmente el análisis de correlación canónica (Wilks, 2006).

Para el caso específico de América Central, la precipitación estacional presenta dos regímenes: uno característico de la vertiente pacífica y uno de su vertiente caribe. No obstante, este segundo régimen apenas representa un 8% de la variabilidad total de la precipitación de América Central, siendo característico principalmente de las costas caribeñas de Honduras y Costa Rica (Alfaro, 2002). La diferencia entre ambos regímenes

se debe en parte a la interacción de los vientos alisios con la compleja topografía de la región centroamericana (Maldonado et al., 2017). Estos vientos representan el régimen predominante de viento en América Central y su intensidad varía en función del comportamiento de la Alta Subtropical del Atlántico Norte. (Maldonado et al., 2018).

En el sector pacífico se presenta una estacionalidad bien marcada, con una época seca definida, la cual se extiende de diciembre a abril y una época lluviosa caracterizada por dos máximos de lluvia, el primero en los meses de mayo y junio y el segundo entre agosto y octubre (Alfaro, 2002). Ambos máximos se encuentran separados por una reducción de las lluvias en el mes de julio, llamado “veranillo” (Magaña et al., 1999), lo cual ocurre por una intensificación de los vientos alisios (Waylen et al., 1996; Gouirand et al., 2013). Por su parte, en la vertiente caribe de América Central no se presenta una estacionalidad marcada, sino condiciones lluviosas durante prácticamente todo el año, con un comportamiento opuesto al de la vertiente pacífica. Durante el invierno boreal, cuando se presentan condiciones secas en el sector pacífico, en el caribe se presentan un período importante de lluvias producto de la intrusión de empujes fríos provenientes de las latitudes medias del hemisferio norte (Maldonado et al., 2017). Adicionalmente, durante el mes de julio, producto de la intensificación de los vientos alisios, se genera un aumento de las precipitaciones en la vertiente caribe, mientras que en el período comprendido entre agosto y octubre (segundo máximo de lluvia en el pacífico), la vertiente caribe presenta una disminución relativa de la precipitación, como consecuencia del debilitamiento de los alisios (Maldonado et al., 2013).

En una escala interanual, la precipitación de América Central se ha relacionado principalmente con moduladores del clima de gran escala, tales como El Niño Oscilación del Sur (ENOS). Específicamente, las fases cálidas (frías) de ENOS se han asociado a condiciones más secas (húmedas) en el sector pacífico (caribe) (Maldonado et al., 2017). Dicha influencia tiende a ser más significativa durante el segundo semestre del año, al final del verano y comienzos del otoño boreal (Alfaro, 2007). No obstante, también se ha observado que, para un mejor entendimiento de la variabilidad de la precipitación en

América Central, es necesario considerar la variación interanual de la temperatura superficial del mar en el Atlántico Tropical, en especial en términos del contraste que se presenta con respecto a la condición térmica del Pacífico Oriental Tropical (Enfield y Alfaro, 1999; Spence et al., 2004; Maldonado et al., 2013; Maldonado et al., 2017)

En el sector de la cuenca del mar Caribe se presenta un ciclo anual de la precipitación similar al del régimen pacífico de América Central, con una época seca en el invierno boreal, de diciembre a abril, y una época lluviosa de mayo a noviembre. Además, la época húmeda presenta un comportamiento bimodal, con un primer máximo de lluvia en mayo y un segundo máximo en septiembre, así como un mínimo relativo de precipitación en julio (Giannini et al., 2000; Gouirand, 2013). Al igual que los estudios realizados para América Central, en términos de las anomalías térmicas de los océanos circundantes, se ha determinado que ENOS tiene una fuerte influencia en la variabilidad de la precipitación de la cuenca del Caribe. En particular se ha observado que el efecto de ENOS es mayor durante los meses de verano y otoño, en especial cuando se presenta un contraste con la temperatura superficial del mar en el sector atlántico (generando un gradiente zonal). Mientras que durante los meses que comprende la transición de primavera a verano, el principal efecto proviene del comportamiento de las anomalías térmicas del Atlántico Norte Tropical (Spence, 2004).

Para efectos del estudio de la variabilidad de la precipitación de la cuenca del Caribe, también se han considerado de manera conjunta los patrones de presión a nivel del mar y de temperatura superficial del mar de un dominio circundante a la cuenca. Se ha establecido que aproximadamente 30% de la varianza total de la precipitación de la cuenca del Caribe puede ser explicada en términos de la variabilidad climática interanual de ENSO y de la Alta Subtropical del Atlántico Norte (Giannini et al., 2000; Giannini et al., 2001). Adicionalmente, se determinó que en la costa caribeña de Honduras y a lo largo de la vertiente caribeña de Costa Rica, el comportamiento de la precipitación estacional durante los meses del invierno boreal difiere del presentado por el resto de la cuenca del Caribe (Giannini et al., 2000). Esto muestra la particularidad climática de la vertiente

caribe de Costa Rica, la cual no comparte el patrón típico de la precipitación estacional de América Central o de la cuenca del Caribe.

Manteniendo igualmente un enfoque regional, también se ha estudiado la potencial capacidad que tienen ciertas variables para pronosticar la precipitación estacional. Para esto se han utilizado esquemas predictivos basados principalmente en análisis de correlación canónica y tablas de contingencia, siendo la temperatura superficial del mar la principal variable predictora (Alfaro, 2007; Fallas-López y Alfaro, 2012a, Fallas-López y Alfaro, 2012b, Maldonado et al., 2013; Maldonado et al., 2017). Dichos esquemas predictivos se han enfocado en el análisis de la predictibilidad de los dos períodos lluviosos que caracterizan el patrón bimodal de la precipitación del sector pacífico de América Central. Esto debido a que dicho patrón representa el principal modo de precipitación en Centroamérica, explicando cerca del 86% de la varianza total (Alfaro, 2002).

A partir de estos esquemas predictivos se ha observado que las correlaciones asociadas a la capacidad de pronóstico varían tanto en el espacio como en el tiempo, siendo éstas, en general, mayores para la vertiente pacífica de América Central y para la segunda mitad del año (Alfaro, 2007; Fallas-López y Alfaro, 2012b). Existen algunas subregiones centroamericanas, en las cuales se presentan comportamientos diferentes al resto de la región. Por ejemplo, países como Costa Rica y Honduras presentan muy bajas correlaciones para la predicción de la precipitación en el primer trimestre de la época lluviosa (mayo-junio-julio), lo cual se contrasta con las altas correlaciones registradas en el resto de la región para este mismo período (Alfaro, 2007).

En los estudios realizados a nivel de Centroamérica y el Caribe, en general se han planteado las relaciones existentes entre patrones de gran escala y la precipitación estacional e interanual. Sin embargo, existe la limitación de que dichas relaciones no son directamente extrapolables a escalas espaciales más reducidas, como por ejemplo el análisis a nivel de un país como Costa Rica. Algunos autores advierten que los resultados de sus estudios deben ser interpretados a escala regional y que es probable que existan

subregiones que presenten zonas con mayores o menores correlaciones que las obtenidas por ellos (Spence, 2004; Maldonado et al., 2017). Esto se puede deber a la distribución espacial de las estaciones meteorológicas consideradas en los estudios, las cuales pueden generar una ponderación espacial de las correlaciones entre variables, o bien al uso de información de precipitación proveniente de conjuntos de datos de mallas regulares, con resoluciones que son gruesas para regiones más específicas, como por ejemplo mallas de $0.5^{\circ} \times 0.5^{\circ}$ (Spence, 2004; Alfaro, 2007).

1.2 Problema de investigación

Para el caso específico de Costa Rica, la precipitación estacional tiende a presentar un comportamiento diferente al resto de la región, especialmente a lo largo de su vertiente caribe. En relación al efecto de las anomalías térmicas y de presión sobre la precipitación de Costa Rica, el análisis se ha enfocado principalmente al estudio de ENOS, debido a sus efectos tan marcados en el país, principalmente producto de las sequías e inundaciones a las cuales ha sido asociado (Instituto Meteorológico Nacional, 1998). A escala local, se ha observado que la precipitación media anual en los años de fase cálida de ENOS generan disminuciones mayores a 400 mm a lo largo de la vertiente pacífica y un aumento de las precipitaciones en la vertiente caribe. Sin embargo, en los años de la fase fría de ENOS, el aumento esperado de la precipitación en la vertiente Pacífica también se presenta en la vertiente caribe (Waylen et al., 1996). Por lo tanto, se puede observar que en la vertiente del caribe costarricense la precipitación estacional no es explicada exclusivamente por ENOS, sino que existen otros fenómenos involucrados que actúan para modular la precipitación en dicha vertiente, lo cual vislumbra una mayor complejidad, si se compara con el caso de la vertiente pacífica.

A nivel regional se ha establecido que la variabilidad de la precipitación estacional e interanual no es explicada solamente por el comportamiento de ENOS, sino que existen otros fenómenos involucrados de gran relevancia. Tal es el caso de la variabilidad de las anomalías térmicas del Atlántico Norte Tropical (Maldonado et al., 2013, Maldonado et al., 2017), el efecto de la Alta Subtropical del Atlántico Norte (Giannini, 2000) y los

correspondientes gradientes zonales que se generan por el contraste con las condiciones del Pacífico Tropical Oriental. No obstante, para el caso específico de Costa Rica, no se ha analizado en detalle el efecto que tienen los patrones anteriores térmicos y de presión de los océanos circundantes sobre la precipitación estacional, especialmente en la vertiente caribe del país, ya que ésta representa un caso particular del comportamiento regional que ya ha sido estudiado (Alfaro, 2007, Fallas-López y Alfaro, 2012b, Maldonado et al., 2013; Maldonado et al., 2017). Esto se debe en parte a la escala espacial que se ha utilizado en estudios anteriores a nivel regional, la cual resulta muy gruesa para el caso de Costa Rica y su alta variabilidad climática.

El desconocer el efecto que tienen las anomalías térmicas oceánicas y de presión atmosférica sobre la precipitación estacional de Costa Rica dificulta la generación de pronósticos estacionales adecuados. Dichos pronósticos son necesarios para la planificación oportuna de actividades económicas que dependen directamente de las lluvias, tales como agricultura, ganadería, silvicultura, producción hidroeléctrica y turismo. Por lo tanto, siempre existe la necesidad de poder cuantificar la habilidad predictiva de las variables explicativas, con el objetivo de evaluar su utilidad como herramienta de pronóstico.

1.3 Hipótesis de investigación

La variabilidad de la precipitación estacional de cada una de las vertientes de Costa Rica es explicada por el efecto combinado de las anomalías térmicas y de presión de los océanos Pacífico y Atlántico, producto de la ubicación geográfica que tiene el país en medio de ambos océanos. Dichas anomalías pueden funcionar como variables predictoras para la realización de pronósticos operacionales regionales dentro de Costa Rica.

1.4 Objetivos

El objetivo principal del presente estudio es determinar el efecto que tienen en la precipitación estacional de Costa Rica los patrones anteriores térmicos y de presión de los océanos circundantes, por medio del uso de modelos empíricos estadísticos lineales, evaluando a su vez la capacidad real que tienen dichos patrones para pronosticar la precipitación estacional. Por lo tanto, este trabajo busca también contribuir en el conocimiento relacionado al verdadero poder predictivo de la temperatura superficial del mar, la cual ha sido ampliamente usada en estudios previos a nivel centroamericano.

Para llevar a cabo el cumplimiento del objetivo principal del estudio se definieron los siguientes objetivos específicos:

- Identificar los principales patrones de la precipitación estacional en las diferentes regiones pluviales de Costa Rica.
- Determinar la relación entre la precipitación de Costa Rica y las anomalías térmicas y de presión de los océanos circundantes.
- Evaluar la habilidad de pronóstico de las anomalías térmicas y de presión de los océanos circundantes en la precipitación estacional de Costa Rica.

2 DATOS Y MÉTODOS

2.1 Características de la zona de estudio

Costa Rica se encuentra en América Central, la cual corresponde a la región geográfica comprendida entre América del Norte y América del Sur. Propiamente, Costa Rica se encuentra entre los 8° y 12° de latitud norte y los 82° y 86° de longitud oeste, limitando al norte con Nicaragua y al sur con Panamá. Adicionalmente, se encuentra en medio de dos grandes masas de agua, el océano Pacífico al oeste y el mar Caribe al este, por lo que la influencia oceánica tiene un efecto directo en el clima del país.

A pesar de su extensión territorial de apenas 51.100 km², Costa Rica presenta una alta variabilidad climática, dentro de la cual se pueden señalar 6 regiones climáticas: Región Pacífico Norte, Región Pacífico Central, Región Pacífico Sur, Región Valle Central, Región Norte y Región Caribe (Manso et al, 2005). Estas regiones se definen en función de la temperatura media anual, la precipitación total anual, el régimen de precipitación anual y el concepto de zonas de vida (Solano y Villalobos, 2001).

En términos propiamente de la precipitación estacional, Costa Rica se puede dividir en dos grandes regiones, la vertiente pacífica y la vertiente caribe. Ambas regiones quedan separadas físicamente por el sistema montañoso de Costa Rica, el cual presenta una orientación noroeste – sureste y elevaciones que en algunos sectores superan los 3000 m.s.n.m. En la Figura 2-1 se muestra la configuración que posee la orografía de Costa Rica y la distribución espacial de las regiones climáticas mencionadas anteriormente. Para efectos del presente estudio, la vertiente pacífica contempla las regiones Pacífico Norte, Pacífico Central, Pacífico Sur y Valle Central, mientras que la vertiente caribe contempla las regiones Norte y Caribe.

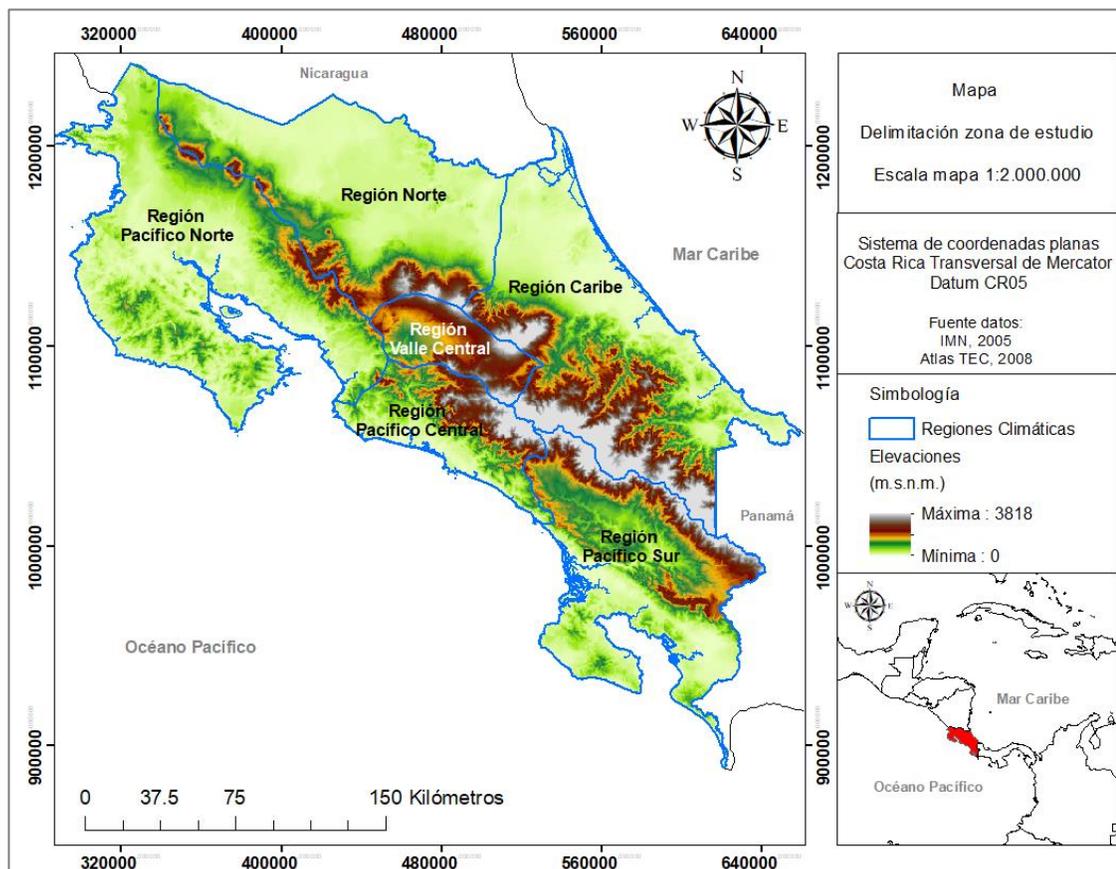


Figura 2-1: Mapa del relieve de Costa Rica

Las características que posee dicho sistema montañoso permite que actúe como un modulador de la precipitación en Costa Rica, ya que su configuración es perpendicular a los vientos alisios predominantes que ingresan al país con dirección noreste, los cuales a su vez representan uno de los principales medios de transporte de humedad a la región (Maldonado et al., 2018). En general, los vientos alisios que ingresan a Costa Rica generan precipitación a lo largo de la vertiente caribe y producen un efecto de sombra de lluvia en la vertiente pacífica, no obstante, la intensidad de estos vientos varía a lo largo del año, siendo más intensos en el verano boreal y menos intensos durante el invierno boreal (Waylen et al., 1996). Adicional a los vientos alisios, la migración de la Zona de Convergencia Intertropical (ZCIT) y los Vientos del Norte representan también importantes controladores de la precipitación estacional. El primero es responsable del

comportamiento bimodal de la precipitación en el sector pacífico, ya que el movimiento latitudinal de la ZCIT tiene influencia en el inicio y finalización de la época lluviosa, debido a su movimiento hacia el norte y hacia el sur, respectivamente (Waylen et al., 1996, Alfaro, 2002 y Maldonado et al., 2018). Por su parte, los vientos del norte se presentan principalmente durante los meses de invierno y son producto de fuertes gradientes meridionales de presión. Estos vientos se calientan y adquieren humedad en el golfo de México y en el mar Caribe y, producto de la orientación de la línea de costa de la vertiente caribe, se generan fuertes precipitaciones locales de tipo convectivo (Waylen et al., 1996).

Al igual que para el caso general de América Central, la vertiente pacífica de Costa Rica presenta una precipitación con una marcada estacionalidad. La época seca se presenta entre diciembre y marzo y la época lluviosa se desarrolla principalmente entre mayo y noviembre (Manso et al., 2005), con una disminución relativa de las precipitaciones en los meses de julio y agosto, fenómeno que se conoce con el nombre de “veranillo” (Magaña et al., 1999).

En la vertiente caribe no existe propiamente una estación seca, ya que las lluvias se mantienen entre 100 mm y 200 mm en los períodos más secos, los cuales se presentan entre febrero – abril y septiembre – octubre (Manso et al., 2005). Esto implica que el primer período está en fase con la estación seca de la vertiente pacífica mientras que el segundo coincide con el período más húmedo de dicha vertiente. La vertiente caribe presenta también dos períodos de mayor precipitación: el primero en el mes de julio, coincidente con el “veranillo” de la vertiente pacífica, y el segundo en los meses de noviembre y diciembre (Manso et al., 2005, Alfaro, 2002). En la Figura 2-2 se muestra la comparación gráfica de la variación de la precipitación estacional entre las vertientes caribe y pacífica. Las gráficas de la Figura 2-2 se construyeron a partir de los datos suministrados por el Instituto Meteorológico Nacional (IMN), los cuales se explican en detalle en la siguiente sección.

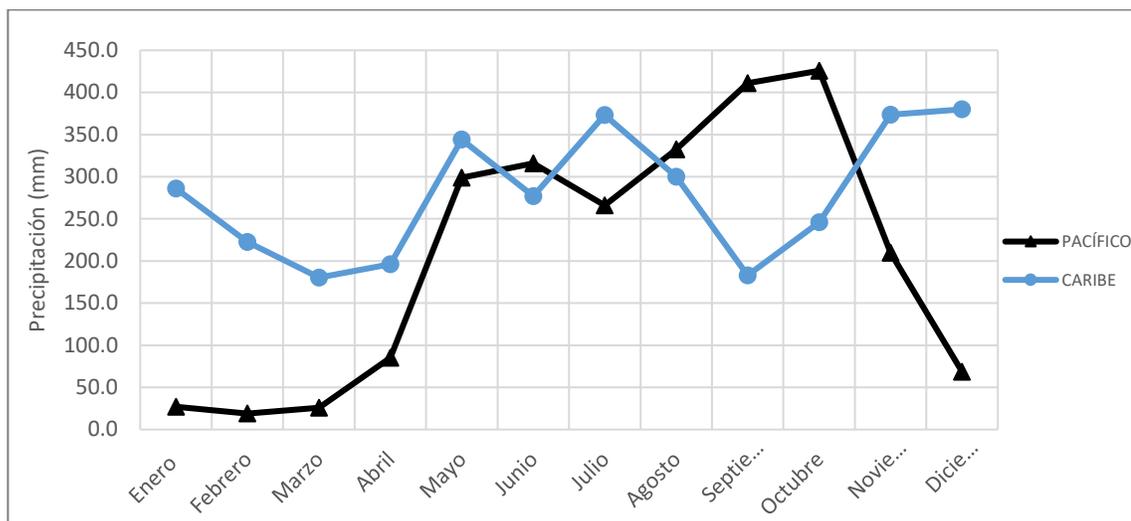


Figura 2-2: Variación estacional de la precipitación según la vertiente

2.2 Datos

La información utilizada para la elaboración del presente estudio se divide en dos grupos, la información de precipitación, correspondiente a la variable de respuesta y la información de la temperatura superficial del mar y presión a nivel, las cuales representan las variables explicativas.

2.2.1 Precipitación

La información de precipitación considerada fue aportada por el IMN. Esta institución está a cargo de la meteorología del país en los ámbitos continental, marítimo y aéreo.

La información suministrada por el IMN corresponde a la precipitación total mensual de 25 estaciones. Adicional a las estaciones del IMN, se dispuso de la precipitación total mensual de 2 estaciones del Centro Agronómico Tropical de Investigación y Enseñanza (CATIE), información que se encuentra disponible en <https://www.catie.ac.cr/productos-y-servicios/estacion-meteorologica.html>. Para las 27 estaciones disponibles se consideró el período comprendido entre enero de 1980 y diciembre de 2019. En la Figura 2-3 se

muestra la distribución espacial de las estaciones consideradas para el presente estudio. Se puede observar que las estaciones utilizadas se encuentran distribuidas a lo largo de las dos vertientes del país, sin embargo, existe una mayor densidad en la vertiente pacífica. Desde el punto de vista de las diferentes regiones climáticas, se dispone de un mínimo de dos estaciones por región, siendo las del pacífico central y el pacífico sur las regiones que disponen de solamente dos estaciones.

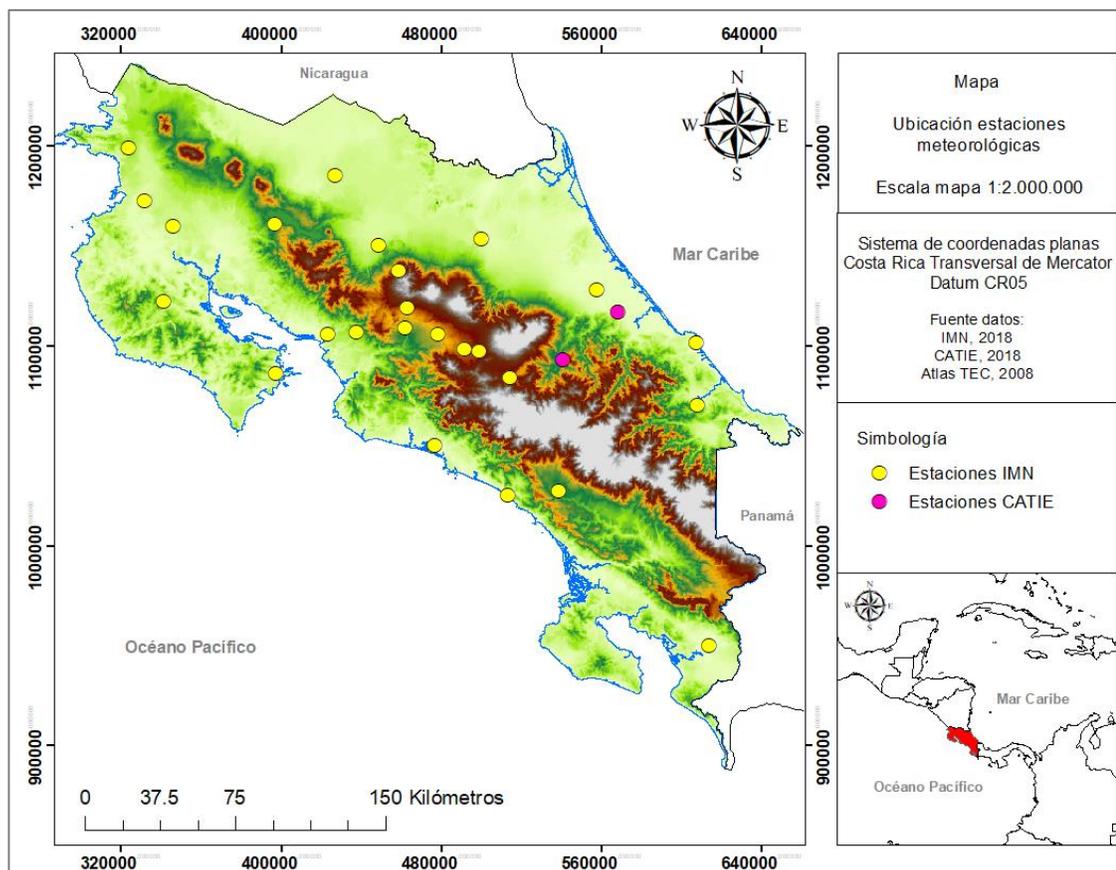


Figura 2-3: Distribución espacial de las estaciones meteorológicas consideradas

2.2.2 Variables explicativas

Las variables explicativas, según la hipótesis planteada, corresponden a la temperatura superficial del mar (SST, por sus siglas en inglés) y la presión a nivel del mar (SLP, por

sus siglas en inglés). Ambas variables se obtuvieron a partir de reanálisis desarrollados por la Administración Nacional Oceánica y Atmosférica de Estados Unidos (NOAA, por sus siglas en inglés).

La información de SST se obtuvo a partir del reanálisis ERSST Versión 5 (Boyin et al., 2017), el cual está disponible en una cuadrícula con una resolución espacial de $2^\circ \times 2^\circ$. Específicamente se utilizaron las anomalías de SST a escala mensual, en el mismo período disponible para la precipitación. El dominio espacial abarcó una extensión comprendida entre los 30°N y 30°S de latitud y 140°E y 10°O de longitud. Se consideró dicho dominio debido a que comprende los fenómenos de ENOS y las anomalías térmicas del Atlántico Norte Tropical, los cuales han sido principalmente asociados con el comportamiento de la precipitación estacional en América Central (Alfaro, 2007; Alfaro et al., 2016; Maldonado et al., 2017). Adicionalmente, el dominio espacial se extendió hasta los 30°S , con el objetivo de evaluar si la variabilidad de las anomalías térmicas de los océanos Pacífico y Atlántico en dichas latitudes presentan teleconexión con la precipitación en Costa Rica.

La información de SLP se adquirió a partir del reanálisis NCEP-DOE R2 (Kanamitsu et al., 2002), el cual tiene una resolución de $2,5^\circ$ en latitud y longitud. Al igual que con la SST, se utilizaron valores a escala mensual, considerando el período en común con la información de precipitación. Para este caso, el dominio espacial se mantuvo igual que para las anomalías térmicas, con la única excepción de que hacia el norte el dominio se extendió hasta los 60°N , con objeto de abarcar la Alta Subtropical del Atlántico Norte (ASAN). Este anticiclón semipermanente tiene gran influencia en la precipitación de Centroamérica y Costa Rica, ya que es responsable de los fuertes vientos alisios que llegan a la región (Maldonado et al., 2018). Además, la ASAN ha sido identificada como una variable responsable de la modulación de la precipitación estacional en América Central y en la cuenca del Caribe (Giannini, 2000).

2.3 Metodología

La metodología del presente estudio se enfocó en el análisis de las relaciones, el efecto y la potencial capacidad de pronóstico que tienen las variables SST y SLP sobre la precipitación estacional de Costa Rica, diferenciada a escala mensual. Esto se llevó a cabo por medio de la construcción de modelos de regresión lineal múltiple para cada uno de los meses considerados. Dichos modelos se construyeron a partir de los componentes principales más relevantes de los campos de precipitación, SST y SLP.

El realizar el análisis a escala mensual tiene como objetivo evaluar la existencia de relaciones más específicas entre las variables explicativas consideradas y la precipitación. Esto tiene una mayor importancia para el caso de la vertiente caribe de Costa Rica, donde no se presenta el patrón bimodal característico de la precipitación que tiene la vertiente pacífica de Costa Rica y Centroamérica, en el cual se han basado estudios previos para considerar la precipitación estacional agrupada en períodos de dos o tres meses (Alfaro, 2007; Fallas y Alfaro, 2012; Maldonado et al., 2013; Maldonado et al., 2017; Alfaro et al., 2016). A raíz de esto, la metodología de análisis contempló, a escala mensual, el período de lluvias de la vertiente pacífica (mayo – octubre) y la totalidad de los meses del año para el caso de la vertiente caribe.

2.3.1 Funciones ortogonales empíricas y componentes principales

Las funciones ortogonales empíricas y los componentes principales, de aquí en adelante denominados como EOF y PC, respectivamente, hacen referencia comúnmente al mismo tipo de análisis, por lo tanto, se pueden considerar como términos intercambiables. Ambos métodos se definen matemáticamente como transformaciones lineales ortogonales que transforman la información original en un nuevo sistema de coordenadas (Valdés-Pineda, 2014). Es un enfoque muy utilizado para el análisis de la variabilidad espacial y temporal de campos físicos, ya que se usa para encontrar un número relativamente pequeño de variables nuevas que contengan la mayor cantidad de información posible del conjunto

original de datos. Estas nuevas variables son las combinaciones lineales de las variables originales que representan la máxima porción de la variabilidad contenida en los datos originales. Adicionalmente, un análisis de componentes principales puede ser útil para explorar conjuntos multivariados de datos, tales como el caso de los campos de variables geofísicas. Esto debido a que tiene el potencial para generar percepciones en cuanto a la variación espacial y temporal de los campos analizados y por lo tanto pueden sugerirse nuevas interpretaciones de la información, producto de la naturaleza de las principales combinaciones lineales generadas (Wilks, 2006).

La relación entre los datos originales, A , los EOF y los PC está dada de la siguiente forma:

$$A(x, y, t) = \sum_{m=1}^M PC_m(t) EOF_m(x, y) \quad (2.1)$$

Los EOF representan la estructura espacial de la información. Siguiendo lo expuesto por Preisendorfer (1988), los EOF se pueden obtener a partir de la matriz de varianza-covarianza, C , de los datos centrados, enfocándolo como un problema de autovalores, para los cuales es necesario resolver el sistema

$$(C - \lambda I)v = 0 \quad (2.2)$$

donde:

C : Es la matriz de varianza-covarianza de los datos centrados A'

λ : Son los autovalores

v : Son los autovectores

I : Es la matriz identidad

El sistema de la ecuación (2.2) tiene solución (para el caso no trivial de $v \neq 0$) cuando la matriz de coeficientes, en este caso $(C - \lambda I)$ es singular. Esto último se presenta cuando el determinante de dicha matriz es cero

$$\det(C - \lambda I) = 0 \quad (2.3)$$

A partir de lo anterior, un escalar λ es un valor propio de la matriz C si y solo si es solución de la ecuación (2.3). Por lo tanto, para encontrar los valores y vectores propios en este tipo de problemas, primero se resuelve la ecuación (2.3), y posteriormente, para cada valor propio se obtiene el correspondiente vector propio, a partir del sistema de ecuaciones en (2.2).

Los vectores propios resultantes del proceso anterior corresponden propiamente a los *EOF*, por lo que éstos representan los nuevos ejes sobre los cuales se re proyectan los datos originales. Estos ejes a su vez representan las direcciones donde se presenta la mayor variabilidad de los datos, la cual se puede cuantificar por medio de los respectivos valores propios, ya que estos últimos corresponden a una medida de la varianza explicada por los vectores propios.

Finalmente, los m componentes principales, PC_m , se obtienen proyectando la matriz original de datos A sobre las funciones ortogonales empíricas estimadas:

$$PC_m = A * EOF_m, \quad m = 1 \dots M \quad (2.4)$$

Los componentes principales muestran la variación temporal de cada una de las estructuras espaciales (*EOF*), por lo que los *PC* son por definición ortogonales entre sí. Es importante hacer notar que existen tantos *PC* como *EOF* se seleccionen. Tomando en cuenta que uno de los objetivos de este tipo de análisis es la reducción de las múltiples dimensiones de los datos, la elección del número de *EOF* se basa en lograr representar una porción significativa de la varianza del campo de la o las variables originales. Para la escogencia de la cantidad de *EOF* a considerar no existe un único criterio, ya que debe considerarse la cantidad total de varianza explicada, los tamaños relativos de los

autovalores y las interpretaciones del fenómeno según los componentes seleccionados (Johnson y Wichern, 1982). En términos de la cantidad total de varianza explicada, Wilks (2006) menciona que entre 70% y 90% se puede considerar un rango aceptable. No obstante, se aclara que esto hace referencia a un criterio subjetivo y que depende del conocimiento del investigador en el tema.

Para efectos del presente estudio, se realizó un análisis de EOF/PC tanto para el caso de la precipitación en Costa Rica como para el caso de las variables explicativas (SST y SLP). Por lo tanto, el análisis de las relaciones lineales entre la variable dependiente y las variables independientes se generaron a partir de los *PC* seleccionados para cada campo considerado, con el objetivo de reducir la dimensionalidad del problema. Dicha reducción se realiza con el propósito de obtener la información más relevante de los datos originales, lo cual a su vez genera una mayor robustez en los resultados que se deriven y evita problemas de sobreajuste en los modelos de regresión.

2.3.2 Modelos de regresión lineal

El análisis de regresión es una metodología estadística utilizada para pronosticar valores de una o más variables de respuesta (dependientes) a partir de los posibles valores de las variables predictoras (independientes). Adicionalmente, esta metodología puede ser usada para evaluar los efectos de las variables predictoras en las variables de respuesta (Johnson y Wichern, 1982). Los modelos empíricos de regresión lineal han sido utilizados en diferentes regiones para el análisis y pronóstico de la precipitación estacional, generando resultados apropiados (Ward y Folland, 1991; Folland et al, 2001; Lloyd-Hughes y Saunders, 2002), en especial tomando en cuenta la simplicidad de este tipo de modelos en comparación con los modelos dinámicos de clima, los cuales requieren altos costes computacionales.

Por medio de la construcción de modelos de regresión lineal múltiple se analizaron las relaciones entre la precipitación estacional en Costa Rica y las variables explicativas (SST

y SLP). A estos modelos se les evaluó su habilidad predictiva real, con el objetivo de comprender su utilidad como herramientas de pronóstico para la precipitación estacional.

Un modelo de regresión lineal múltiple con p predictores se puede expresar de la siguiente forma:

$$\begin{aligned} Y &= \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \\ Y &= f(X) + \epsilon \end{aligned} \quad (2.5)$$

donde X_j representa al predictor j y β_j es el coeficiente que cuantifica la asociación entre dicho predictor y la variable de respuesta Y . El término ϵ corresponde al error y representa la información que no se logra estimar a partir del modelo propuesto. Este error se puede deber a que la relación que se está modelando no es realmente lineal, por lo que podrían existir otras variables que tengan un efecto en la variación de Y (James et al., 2000).

Partiendo del hecho que se tienen disponibles n observaciones, tanto para la variable de respuesta como para los predictores, el modelo descrito en (2.5) representa n ecuaciones que describen como la variable de respuesta es generada en el proceso modelado (Walpole, 2011). Este conjunto de ecuaciones puede ser expresado de manera más clara en notación matricial

$$\begin{aligned} Y &= X\beta + \epsilon \\ \text{Donde:} \\ Y &= \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad X = \begin{bmatrix} 1 & x_{11} & x_{21} & \dots & x_{p1} \\ 1 & x_{12} & x_{22} & \dots & x_{p2} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{1n} & x_{2n} & \dots & x_{pn} \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix} \end{aligned} \quad (2.6)$$

Para la estimación del vector de coeficientes β , el método más frecuentemente usado es el de Mínimos Cuadrados, en el cual se calculan los coeficientes que minimizan la suma de los errores al cuadrado, *SEC*, (Hastie et al., 2009)

$$SEC(\beta) = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (2.7)$$

Siendo en notación matricial

$$SEC(\beta) = (Y - X\beta)^T(Y - X\beta)$$

Siguiendo el procedimiento algebraico detallado por Hastie et al. (2009), se llega a la siguiente expresión para la estimación de los coeficientes del modelo de regresión

$$\hat{\beta} = (X^T X)^{-1} X^T Y \quad (2.8)$$

El método de Mínimos Cuadrados permite obtener los mejores estimadores lineales insesgados que poseen la mínima varianza, según el teorema de Gauss-Markov (Hastie et al., 2009). Esta propiedad de los Mínimos Cuadrados se cumple cuando son válidos los siguientes supuestos (Walpole, 2011):

- El valor esperado de los residuos es cero: $E(\epsilon) = 0$
- La varianza de los residuos es constante, lo que implica un comportamiento homocedástico de los residuos: $Var(\epsilon) = constante$
- Los residuos son independientes, es decir, no presentan autocorrelación.

2.3.3 Construcción de los modelos de regresión

Como se mencionó al inicio del presente capítulo, el análisis entre las variables predictoras (SST, SLP) y la precipitación estacional en Costa Rica se realizó a nivel mensual, considerando el período comprendido entre enero de 1980 y diciembre de 2015. Por lo tanto, para cada mes fue necesario definir el o los modelos que mejor logaran explicar la relación del fenómeno, lo cual a su vez implicó establecer los predictores más apropiados.

Es importante mencionar que la construcción de los modelos se realizó en el entorno de los componentes principales de las variables involucradas, por lo tanto, los potenciales predictores disponibles corresponden a los componentes principales (PC) de SST y SLP, mientras que la variable de respuesta es representada por un determinado componente principal del campo de la precipitación. Para los modelos de regresión los predictores se consideraron con diferentes desfases temporales con respecto a la variable de respuesta, con el objetivo de analizar la habilidad predictiva de dichos modelos.

Tanto los potenciales predictores como la variable de respuesta, previo a la construcción de los modelos, fueron centrados y normalizados. El objetivo de centrar la información fue obtener coeficientes que solamente contemplen el gradiente que tiene cada predictor con la variable de respuesta. La normalización por su parte se realizó para poder hacer comparables los coeficientes del modelo, de manera que la interpretación de la influencia de cada predictor fuera más clara (Mutai et al., 1998). Es importante mencionar que, en el presente contexto, la normalización hace referencia a dividir los componentes principales entre su correspondiente norma vectorial.

La cantidad de posibles predictores se encuentra en función de la cantidad de PC que se mantengan para cada variable explicativa. Esto implica que puede existir una gran cantidad de potenciales predictores, por lo que es necesario detectar cuáles de éstos son los más relevantes. Como método para establecer el campo de predictores de cada modelo, se realizó una selección progresiva hacia adelante. Este método contempla inicialmente un modelo sin predictores y posteriormente va agregando predictores al modelo en cada iteración, para finalmente llegar a un modelo que incluye todos los predictores (James et al., 2000). Este proceso se combinó con un método de validación cruzada, con el objetivo de evaluar cuál es el mejor predictor para ser agregado al modelo cada vez que se aumenta el número de predictores de éste. Se utilizó el método de la validación cruzada de Monte Carlo (Xu et al., 2004), el cual realiza N veces una separación aleatoria de los datos en dos grupos, un set de calibración y un set de validación. El muestreo realizado para definir los

dos sets se hace sin remplazo, por lo que se garantiza que el set de validación no contempla valores utilizados en el set de calibración del modelo.

Tomando en cuenta el enfoque de la validación cruzada de Monte Carlo y para poder cuantificar la mejora o el detrimento que se obtiene al agregar un determinado predictor al modelo, se estimó la raíz del error cuadrático medio de validación del modelo ($RMSE_{CV}$, por sus siglas en inglés) a partir de las N iteraciones en que se realizaba la validación cruzada, cada vez que se consideraba un nuevo predictor. El RMSE calculado en cada una de las N iteraciones fue normalizado por la “climatología” del correspondiente set de validación. Dicha climatología corresponde al caso en el que la estimación por parte del modelo es nula, de esta manera se logra un RMSE comparable entre las diferentes iteraciones, ya que no se ve afectado por la magnitud de los valores de set de validación. Finalmente, se obtiene el valor medio del RMSE normalizado estimado para cada iteración, correspondiente al $RMSE_{CV}$.

$$RMSE_{CV} = \frac{1}{N} \sum_{m=1}^N RMSE_{normalizado} = \frac{\sqrt{\sum_{j=1}^{n_v} \frac{(\hat{y}_i - y_i)^2}{n_v}}}{\sqrt{\sum_{j=1}^{n_v} \frac{(y_i)^2}{n_v}}} \quad (2.9)$$

Donde y_i es la observación i del set de validación, \hat{y}_i corresponde a la estimación i realizada con el respectivo modelo, n_v es la cantidad de valores del set de validación sobre las cuales se realiza la comparación entre lo observado y lo modelado y N la cantidad de iteraciones en que se realiza la validación cruzada. Según Xu et al. (2004), es suficiente definir N igual a n^2 (donde n corresponde al número de observaciones disponibles) para obtener un buen desempeño por parte de la validación cruzada de Monte Carlo.

La validación cruzada empleada también sirvió como un indicador para limitar la cantidad de predictores que eran agregados al modelo de regresión, ya que, si ningún nuevo predictor generaba una disminución del $RMSE_{CV}$ (considerando los predictores acumulados hasta el momento), el proceso de agregar predictores se detenía. El propósito de dicha condición fue la de obtener modelos con el menor error de validación pero que

simultáneamente fueran lo más parsimoniosos posibles. Igualmente, el valor del $RMSE_{CV}$ de los modelos se utilizó como métrica de comparación entre modelos, por ejemplo, el caso de varios modelos para un mismo mes, con el mismo número de predictores, pero con diferentes desfases temporales del campo de predictores. Para modelos ajustados por mínimos cuadrados, el usar el error de validación cruzada para escoger entre modelos tiene una ventaja en relación a métricas como el criterio de información de Akaike (AIC), el criterio de información bayesiano (BIC) o el coeficiente de determinación ajustado (R^2), ya que la validación cruzada provee una estimación directa del error de testeo y considera menos suposiciones sobre el verdadero modelo subyacente (James et al., 2000).

Adicional a la validación cruzada también se verificó que todos los predictores que se incluyeran en los modelos fueran ortogonales entre sí, lo cual es necesario dado que los PC de SST no son ortogonales con los PC de SLP. Para ello se realizó una ortogonalización sucesiva al set de potenciales predictores cada vez que se agregaba un nuevo predictor al modelo. En otras palabras, se eliminó la proyección del predictor seleccionado sobre los restantes predictores que aún no habían sido escogidos. De esta manera se garantizaba que cada predictor que se le agregaba al modelo ya era ortogonal a los predictores seleccionados previamente, formando una base ortogonal entre ellos. A este procedimiento se le conoce como el procedimiento de Gram-Schmidt para regresión múltiple (Hastie et al., 2009), el cual es una estrategia útil para la estimación de los coeficientes del modelo, ya que éstos se calculan a partir de la contribución adicional de información que aporta cada nuevo predictor.

Esta metodología de selección de predictores fue aplicada para la obtención de los modelos lineales en los meses de análisis, considerando a su vez diferentes desfases temporales entre la variable de respuesta y los potenciales predictores. Esto último con el objetivo de evaluar la variabilidad en la capacidad para pronosticar la precipitación de un determinado mes, considerando la inercia temporal de determinados patrones de SST y SLP.

La significancia estadística de los modelos de regresión se evaluó por medio de un análisis de varianza (ANOVA, por sus siglas en inglés). El análisis de varianza compara la variabilidad explicada con la variabilidad no explicada, mediante el estadístico F. Este análisis parte de la hipótesis nula, H_0 , de que no hay relación de regresión entre la variable dependiente y el conjunto de variables independientes, lo cual implica que:

$$H_0: \beta_i = 0 \quad (2.10)$$

Mientras que la hipótesis alternativa, H_a , establece que existe al menos un coeficiente que es estadísticamente significativo.

$$H_a: \text{algún } \beta_i \neq 0 \quad (2.11)$$

Se analizó también, de manera específica, la significancia estadística de cada uno de los coeficientes (β_i) de los modelos de regresión a partir de las hipótesis anteriores. Esto último se llevó a cabo haciendo uso de la distribución T-Student, para un nivel de significancia de 0,05.

2.3.4 Evaluación de la habilidad de pronóstico

Para efectos de evaluar la habilidad de pronóstico de los modelos, se consideró la precipitación mensual del período comprendido entre enero de 2016 y diciembre de 2019. Este período no se utilizó ni para el entrenamiento ni para la validación de los modelos de regresión, por lo que representa un período completamente nuevo, de manera que sirve para medir la habilidad predictiva real de los modelos.

En la Figura 2-4 se compara la distribución espacial de las estaciones utilizadas para el entrenamiento y validación de los modelos (1980 – 2015) y para la evaluación de su habilidad de pronóstico real (2016 – 2019). Es importante mencionar que para muchas de las estaciones no se contó con datos para el segundo período, por lo que fue necesario recurrir a estaciones que se encontraran cercanas a las utilizadas originalmente.

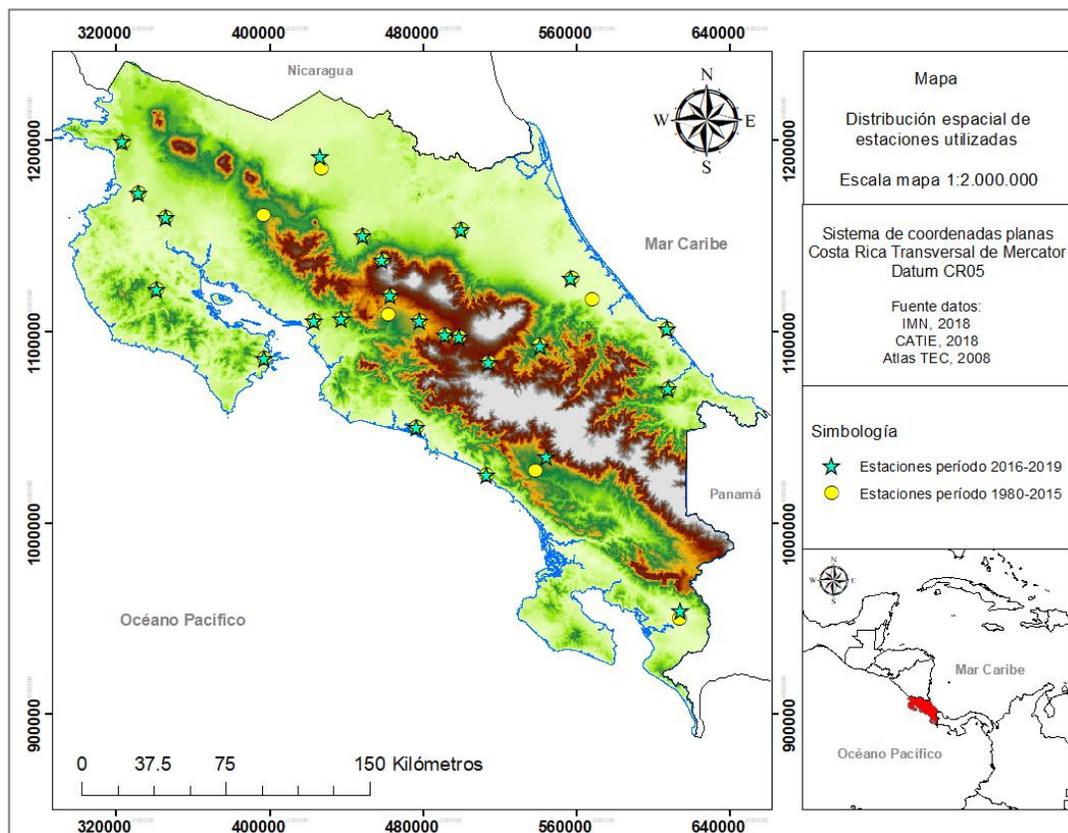


Figura 2-4: Ubicación de estaciones usadas para los períodos de construcción-validación y testeo de los modelos de regresión

Como se puede ver en la Figura 2-4, la distribución espacial para ambos períodos es similar, por lo que se considera que los resultados derivados de los modelos de regresión son comparables con la información disponible para el período de pronóstico. Sin embargo, es relevante mencionar que dentro de dicho período se presentan una cantidad significativa de datos faltantes, por lo que para algunos meses no se contó con un valor observado con el cual se pudiera comparar el valor pronosticado. El porcentaje faltante de datos varió entre un 5% y un 20% de los 48 datos (4 datos para cada mes) que idealmente debería tener cada estación. Esta limitación en la disponibilidad de los datos debe ser tomada en cuenta en la interpretación de los resultados de los pronósticos que se obtengan.

Para evaluar la utilidad de los pronósticos de los modelos de regresión, no solo se consideró un período independiente a los períodos de entrenamiento y calibración de

dichos modelos, sino que el desempeño de éstos fue comparado contra modelos o pronósticos de referencia, los cuales representan un mínimo a ser superado por los modelos de regresión. Los pronósticos de referencia considerados fueron los siguientes (Ward y Folland, 1991):

- *Climatología*: pronóstico calculado a partir del valor medio de precipitación de una determinada ubicación, lo que implica que no se presenta propiamente una anomalía de precipitación.
- *Persistencia*: pronóstico realizado a partir de las anomalías de precipitación observadas en un determinado mes anterior al mes de pronóstico. Es equivalente a un modelo autorregresivo de orden 1 sin ruido.
- *Azar*: pronóstico generado a partir de la elección aleatoria de una distribución histórica de anomalías de precipitación. Para este caso el objetivo fue determinar cuál es la probabilidad de obtener, de manera aleatoria, un pronóstico como el obtenido por el modelo de regresión. El pronóstico al azar se definió solamente para el caso de pronósticos categóricos. Para ello se utilizó la distribución binomial (Walpole, 2011), por medio de la cual se consideraron a los pronósticos categóricos en las estaciones como una secuencia de ensayos independientes entre sí, con una probabilidad fija de ocurrencia del éxito, p , la cual queda definida por la cantidad de categorías en que se divide el pronóstico. La probabilidad, P , de obtener x cantidad de aciertos a partir del pronóstico categórico en n estaciones está dada por la siguiente ecuación:

$$P(x; n, p) = \binom{n}{x} p^x q^{n-x}, x = 0, 1, 2, \dots, n \quad (2.12)$$

Para cuantificar y comparar el desempeño de los modelos desarrollados con el de los pronósticos de referencia se utilizaron tres métricas continuas, la raíz del error cuadrático medio ponderado por la desviación estándar de los valores observados (RSR) (Moriassi et

al., 2007), el sesgo y el error relativo absoluto (RAE) (Bennett et al., 2013). A continuación, se detallan las métricas mencionadas:

$$RSR = \frac{RMSE}{Desv. Estándar} = \frac{\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}}{\sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}}} \quad \text{Rango: } (0, \infty) \quad (2.13)$$

$$Sesgo = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad \text{Rango: } (-\infty, +\infty) \quad (2.14)$$

$$RAE = \frac{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|}{\frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}|} \quad \text{Rango: } (0, \infty) \quad (2.15)$$

Para el caso de las métricas de RSR y RAE, el valor ideal corresponde a 0, mientras que valores superiores a 1 implica que es preferible utilizar el promedio como valor de pronóstico, es decir, un pronóstico basado en la climatología.

Adicional al uso de las métricas continuas y considerando el análisis de los pronósticos generados desde un punto de vista operacional, se realizó también una evaluación del desempeño de los modelos por medio de una métrica discreta. Para ello se utilizó el índice de precipitación estandarizado (SPI, por sus siglas en inglés) como métrica para categorizar las estimaciones, tanto la de los modelos como las de los pronósticos de referencia. El SPI es un método comúnmente utilizado para cuantificar el déficit de precipitación en múltiples escalas temporales. Conceptualmente, el SPI representa el número de desviaciones estándar, por encima o por debajo, de un determinado evento con respecto a su media (Valdés – Pineda, 2014), por lo que se puede usar para analizar tanto condiciones secas como condiciones húmedas.

El cálculo del SPI se realizó llevando a cabo el procedimiento descrito por Mckee et al. (1993), el cual originalmente consideraba escalas de tiempo de 3, 6, 12, 24 y 48 meses, ya que el déficit de precipitación durante dichos períodos de tiempo tiene efecto en diversos campos de interés. Por ejemplo, condiciones meteorológicas y de humedad de suelo responden a las anomalías de precipitación en escala temporales cortas (1 – 6 meses), mientras que la variación en los regímenes de caudal, en los embalses y en el agua subterránea responde a anomalías de precipitación de largo plazo, cercana al orden de 6 meses y hasta 24 meses o más (WMO, 2012).

Para el presente estudio se consideró el SPI para una escala temporal de 1 mes, como métrica discreta para evaluar el desempeño de los modelos. El SPI de 1 mes corresponde a un indicador que refleja la comparación entre la precipitación de un determinado mes de un determinado año con los valores de ese mismo mes en los restantes años del registro (WMO, 2012). Por lo tanto, tanto los valores pronosticados como los valores observados fueron clasificados en categorías según la metodología del SPI, para posteriormente evaluar la cantidad de aciertos categóricos que lograban conseguir los modelos. Las categorías en que se clasifica el SPI se detallan en la Tabla 2-1.

Tabla 2-1: Clasificación de los valores del SPI

SPI	Condición
$\geq 2,0$	Extremadamente húmedo
1,5 – 1,99	Muy húmedo
1,0 – 1,49	Moderadamente húmedo
-0,99 – 0,99	Cercano a Normal

-1,0 – -1,49	Moderadamente seco
-1,5 – -1,99	Muy Seco
$\leq -2,0$	Extremadamente seco

Para efectos del presente estudio, se consideraron solamente 3 posibles categorías para el pronóstico: normal ($-1 < SPI < 1$), húmedo ($SPI > 1$) y seco ($SPI < -1$). De esta manera, la probabilidad de acierto, p , es $1/3$ y la probabilidad de fallo, $q = 1 - p$, es $2/3$, según lo explicado anteriormente referente a la distribución binomial.

3 PREDICTIBILIDAD DE LA PRECIPITACIÓN ESTACIONAL

El análisis de la predictibilidad de la precipitación estacional en Costa Rica se llevó a cabo a partir de la implementación de modelos de regresión lineal múltiple. Tal como se mencionó en la metodología del trabajo, los modelos de regresión lineal se generaron a partir de los componentes principales de los campos de la precipitación, de la temperatura superficial del mar y de la presión a nivel del mar, siendo estas dos últimas las variables explicativas de los modelos. Por lo tanto, se realizó un análisis de EOF/PC a cada una de las variables mencionadas, con el objetivo de reducir la multidimensionalidad del problema y que a su vez permitiera la construcción de modelos de regresión más simples.

El análisis de EOF/PC y por consiguiente el desarrollo de los modelos de regresión, fue realizado para el período comprendido entre enero de 1980 y diciembre de 2015, quedando los últimos cuatro años (i.e. 2016-2019) para evaluar el desempeño de los modelos con datos nuevos, diferentes a los utilizados en la construcción y validación de los modelos. Este enfoque permite obtener conclusiones más confiables referente a la potencial habilidad de pronósticos operacionales, generados a partir de los modelos (Folland et al., 1991).

3.1 Campo de precipitación

El campo de precipitación considerado está compuesto por la precipitación mensual registrada en las 27 estaciones que se muestran en la Figura 2-3. A partir del análisis de EOF realizado se determinó que el 58% de la variabilidad de la precipitación en Costa Rica es explicada por los dos primeros EOF, específicamente 35% por el primero y 23% por el segundo. En la Figura 3-1 se muestran de manera gráfica los primeros 2 EOF del campo de precipitación, los cuales indican un comportamiento claramente diferenciado entre la vertiente caribe y la vertiente pacífica de Costa Rica. Adicionalmente, en cada vertiente se observa una coherencia espacial de las anomalías de precipitación, por lo tanto, se puede establecer que cada EOF representa un modo de precipitación distinto.

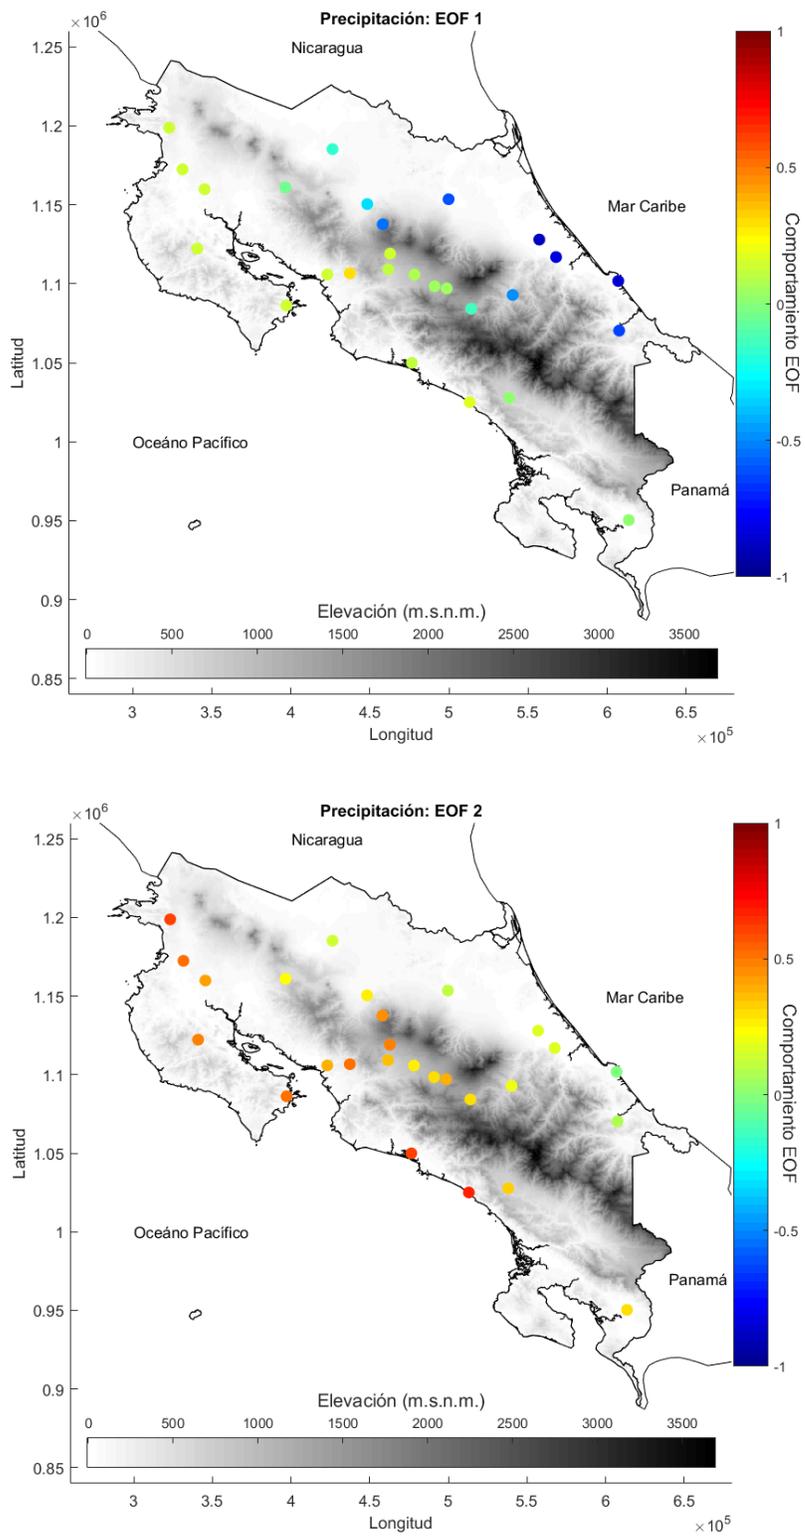


Figura 3-1: Comportamiento espacial de los primeros dos modos de precipitación

En la Figura 3-1 la escala de colores vertical representa un indicador del comportamiento del correspondiente EOF. A partir de dicho indicador se puede determinar cuáles estaciones forman parte en mayor o menor medida del modo de precipitación que representa el EOF y la manera en la que lo hacen. Así, por ejemplo, una estación con un valor cercano a 1 tendrá un comportamiento opuesto a una estación que tenga un valor cercano a -1, siendo ambos casos condiciones relevantes en términos de la variabilidad que explica el EOF. En cambio, un valor cercano a 0 implica que el EOF no explica en gran medida el comportamiento de la precipitación en dicha estación.

El primer EOF, representa la variabilidad de la precipitación principalmente en las regiones climáticas Norte y Caribe, siendo más importante en la última. Por su parte, el segundo EOF corresponde a la precipitación de la vertiente pacífica de Costa Rica, abarcando también la región climática del Valle Central. Comparando las dos imágenes de la Figura 3-1 se puede observar que ambos modos de precipitación se encuentran fuera de fase, ya que cada EOF muestra un comportamiento predominante solo de un lado del sistema montañoso del país, siendo estos resultados congruentes con lo determinado por Waylen et al. (1996), respecto a los regímenes estacionales de precipitación de ambas vertientes. En la Figura 2-2 se puede observar el régimen de precipitación que representan los dos primeros EOF obtenidos, ya que dicha figura se construyó realizando una separación espacial de las estaciones muy similar a la generada por el análisis de EOF.

A partir del análisis de EOF aplicado al campo de precipitación se determinó que la mayor parte de la variabilidad de la precipitación en Costa Rica es explicada por lo que ocurre en su vertiente caribe, lo cual es un resultado que contrasta con lo que se ha determinado a nivel centroamericano. Para América Central, el régimen de precipitación predominante corresponde al comportamiento bimodal, presente principalmente en la vertiente pacífica, (Alfaro, 2002), caracterizado por una fuerte estacionalidad y una época seca definida. Alfaro (2002) también determinó que existe un segundo régimen de precipitación, que apenas representa un 8,2% de la varianza total y que se presenta cerca de las costas

caribeñas de Honduras y Costa Rica, el cual coincide con el primer modo de precipitación encontrado para Costa Rica.

Tomando en cuenta lo expuesto anteriormente, se considera necesario analizar de manera separada los primeros dos modos de precipitación encontrados para Costa Rica. Esto a raíz de que el primer EOF, llamado de aquí adelante modo caribe, representa un régimen de precipitación que no ha sido analizado en detalle en estudios anteriores realizados a nivel centroamericano. Por otra parte, el segundo EOF se definirá de aquí en adelante como modo pacífico.

El considerar de manera separada ambos modos de precipitación, tiene como objetivo también evaluar la capacidad de pronóstico en cada vertiente. Esto a pesar del hecho de que la precipitación en cada estación está compuesta por el efecto combinado de todos los EOF resultantes del análisis, tanto de los dos primeros que se conservan como de los restantes 25 de los cuales se prescinde. Con respecto a esto último, es importante mencionar que la selección de la cantidad de EOF se realizó a partir del análisis del comportamiento espacial de éstos y del porcentaje de varianza explicada acumulada que se obtenía al agregar un nuevo EOF. Por ejemplo, el tercer EOF, el cual se puede visualizar en el Anexo A2, muestra una especie de contraste (no muy claro) entre dos regiones de la vertiente pacífica de Costa Rica, específicamente la región Pacífico Sur y la región Pacífico Norte. Sin embargo, a pesar de que este EOF ayuda a explicar y eventualmente podría también contribuir a mejorar el pronóstico en esas regiones, solamente explica 7% adicional de la varianza total de la precipitación. Por lo tanto, es menos probable que el tercer EOF presente una relación lineal significativa con los predictores y debido a esto no se considera imprescindible para los análisis posteriores. En la Figura 3-2 se muestra el aumento acumulado en el porcentaje de la varianza explicada al incrementar la cantidad de EOF, siendo visible que, posterior a los primeros dos EOF, el incremento en la varianza explicada disminuye significativamente.

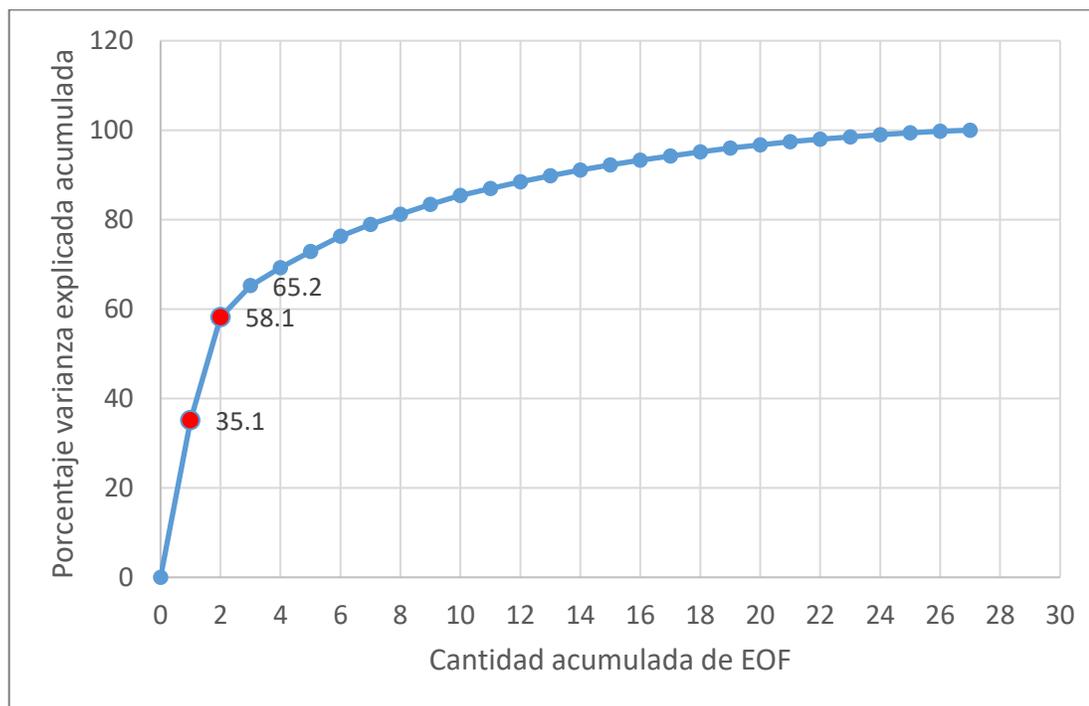


Figura 3-2: Varianza explicada acumulada según la cantidad de EOF considerados

Para cuantificar la representatividad de los dos primeros EOF con respecto al campo de precipitación considerado, se realizó una reconstrucción de las series temporales de precipitación de cada una de las estaciones utilizando solamente los primeros dos EOF. A partir de las series observadas y las series reconstruidas se calculó el coeficiente de determinación (R^2), el cual se utilizó como métrica para cuantificar el ajuste entre ambas series. En la Figura 3-3 se muestra la variación espacial del R^2 , en la cual se puede ver que en general el ajuste es bueno, con valores cercanos o superiores a 0,7. Por lo tanto, a partir de los primeros dos EOF se puede representar en buena medida la variabilidad de la precipitación en Costa Rica.

Un análisis similar al descrito en el párrafo anterior se llevó a cabo usando de manera independiente el primer y el segundo EOF de precipitación, el cual se detalla en el Anexo A3. A partir de dicho análisis se puede concluir que la mejoría del ajuste para la reconstrucción de las series observadas a partir del uso combinado de los primeros dos EOF no es significativo. Esto implica que la variabilidad de la precipitación en la mayoría

de las estaciones se puede representar de manera adecuada a partir de un único EOF, ya sea el primero (modo caribe) o el segundo (modo pacífico). Para efectos del presente estudio, esto justifica el realizar los análisis, la construcción de los modelos de regresión y la generación de los eventuales pronósticos de manera separada para cada uno de los modos de precipitación considerados.

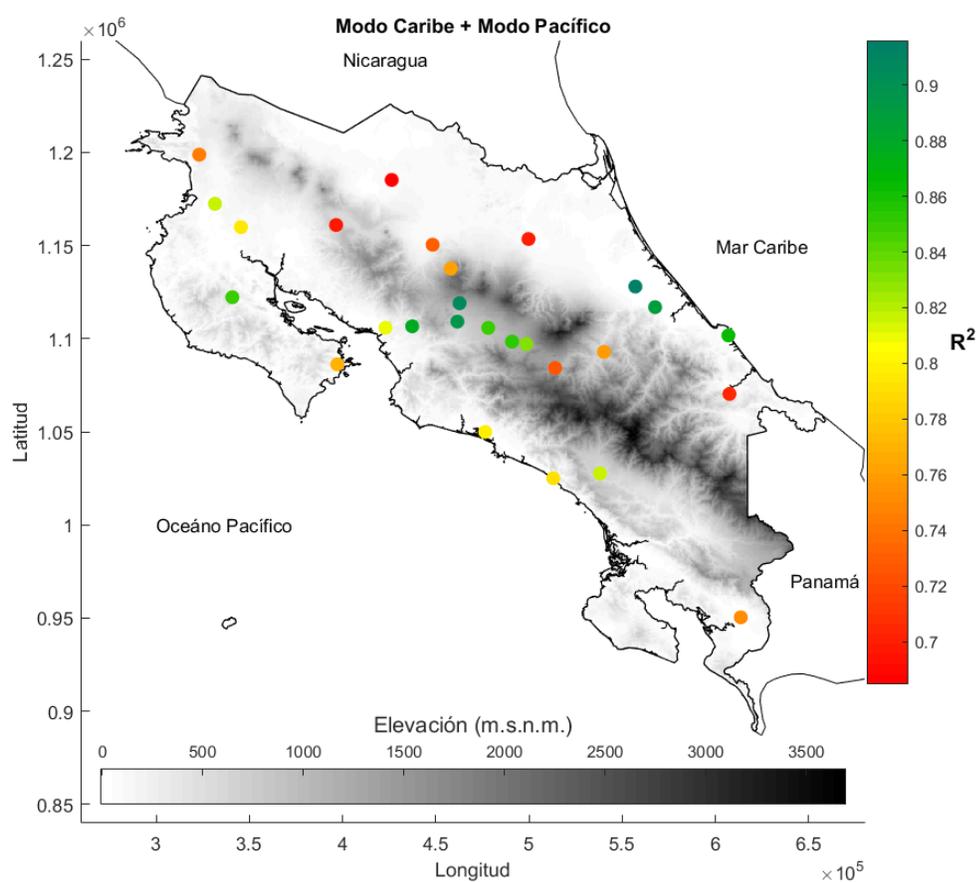


Figura 3-3: Variación espacial del R^2 entre las series de precipitación observadas y las series reconstruidas a partir de los primeros dos EOF

3.2 Campos de las variables explicativas: SST y SLP

Las variables explicativas de los modelos de regresión (SST y SLP) fueron analizadas de manera separada. Esto implicó que el análisis de EOF se realizó igualmente de manera separada para el campo de SST como para el campo de SLP, con el objetivo de evaluar posteriormente, por medio del uso de los modelos de regresión, el efecto que tiene cada variable sobre la precipitación estacional de Costa Rica.

Al igual que con el campo de precipitación, fue necesario determinar la cantidad de EOF que se retienen de cada variable explicativa para los análisis posteriores. Para este caso, se trató de conservar la mayor cantidad de EOF posible, con el objetivo de disponer de la mayor cantidad de potenciales predictores para los modelos de regresión. Como parámetro de corte, se consideró disponer de los EOF necesarios para explicar al menos un 90% de la varianza de cada variable (Wilks, 2006). A partir de este criterio, se retuvieron 27 EOF para la variable de SST y 22 EOF para la variable de SLP. Si bien este criterio de corte se puede calificar como subjetivo, permite disponer de un número de predictores manejable en términos de la construcción de los modelos de regresión y a su vez representan en gran medida la varianza de cada variable. Además, se verificó que cada uno de los EOF retenidos mostrara un comportamiento espacial claro y no un patrón errático que limitara la interpretación física de los modelos de regresión (en caso de ser incluidos en los modelos).

En relación con el comportamiento espacial de los EOF que se retuvieron, vale la pena mencionar que para el campo de SST, el primer EOF, el cual explica prácticamente 38% de la varianza total, presenta un comportamiento espacial predominante a lo largo del sector pacífico ecuatorial, tal como se muestra en la Figura 3-4. Este comportamiento es característico del fenómeno de El Niño Oscilación del Sur (ENOS), el cual representa el principal modo de variación interanual del océano pacífico ecuatorial (Waylen et al., 1996; Alfaro 2007). A una escala interanual, las variaciones de ENOS representan la influencia más dominante de la humedad en la región centroamericana (Maldonado et al, 2018).

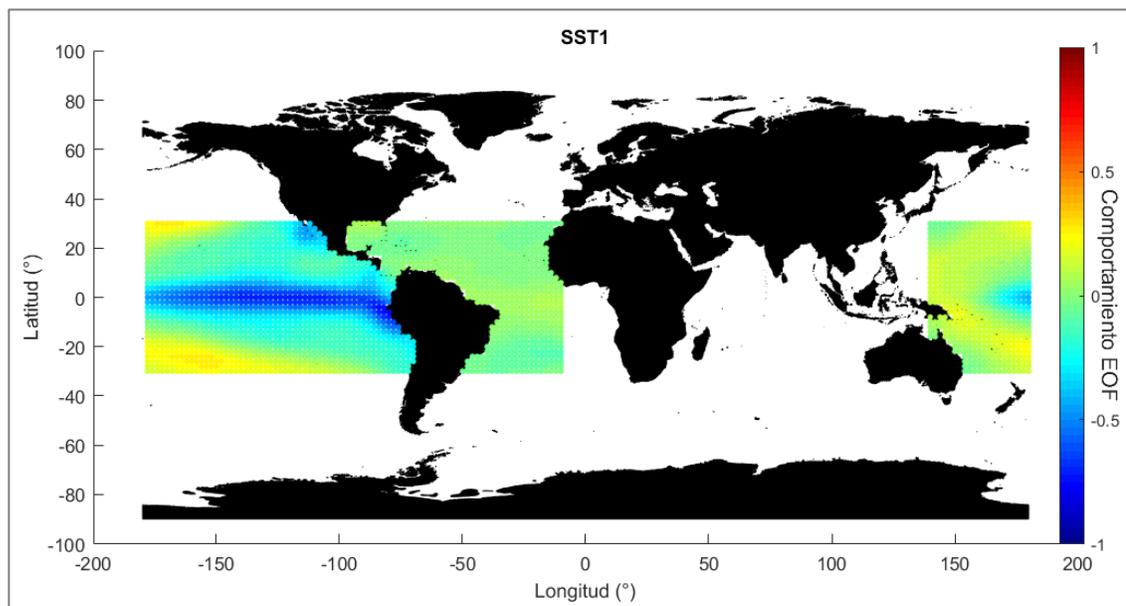


Figura 3-4: Comportamiento espacial del primer EOF de SST

Con respecto a los EOF retenidos para el campo de SLP, la mayor parte de la varianza es explicada por los sistemas de alta presión que se encuentran en la región norte de los océanos Pacífico y Atlántico. Por ejemplo, los primeros cuatro EOF (SLP1, SLP2, SLP3 y SLP4), los cuales muestran un comportamiento espacial exclusivo de la región más septentrional del dominio considerado, explican 54% de la varianza total del campo de SLP. La Figura 3-5 muestra el comportamiento espacial de los primeros cuatro EOF de SLP. Los sistemas de alta presión ubicados cerca de los 30° de latitud norte, tanto en el océano Pacífico (Alta del Pacífico Norte) como en el océano atlántico (Alta Subtropical del Atlántico Norte) producen en promedio un fuerte gradiente de presión meridional entre los subtrópicos y los trópicos, lo cual acelera las masas de aire hacia el ecuador, generando los vientos alisios (Maldonado et al, 2018), responsables en gran medida de la precipitación en Costa Rica.

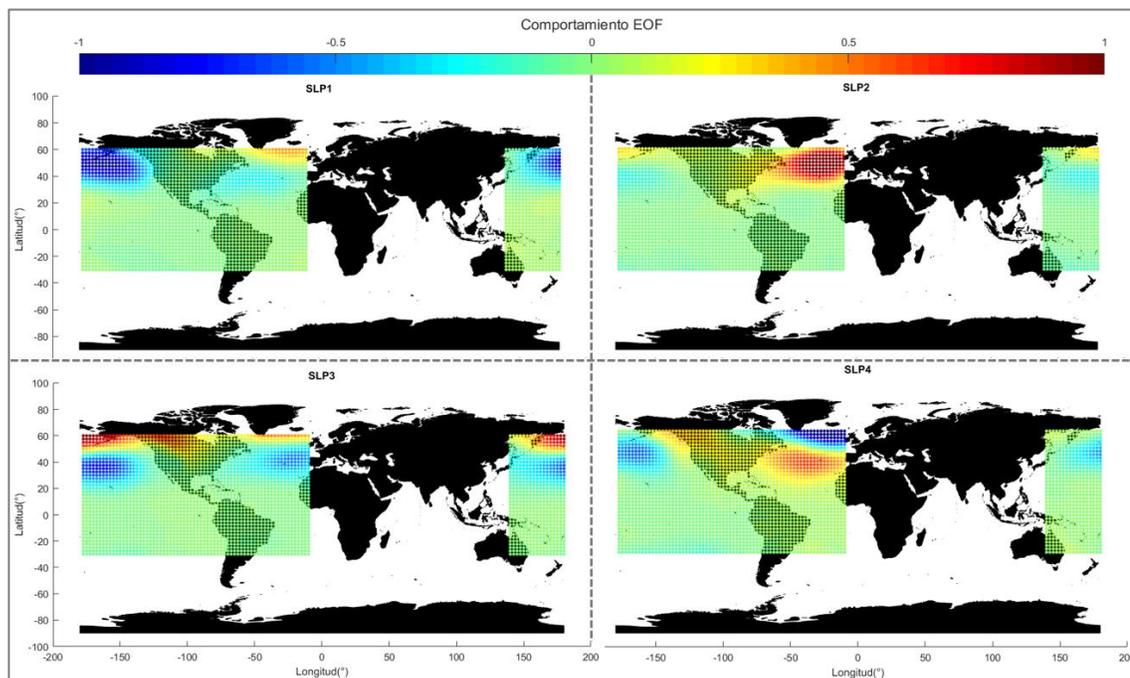


Figura 3-5: Comportamiento espacial de los primeros cuatro EOF de SLP

Dado que tanto ENOS como la Alta Subtropical del Atlántico Norte modulan de manera independiente la precipitación en la región del Caribe y de América Central en una escala de tiempo interanual (Giannini et al., 2001), se consideró apropiado incorporar y analizar, también de manera separada, los patrones térmicos y de presión dentro de los modelos de regresión.

3.3 Correlaciones temporales entre la precipitación y las variables explicativas

Para los EOF retenidos, tanto del campo de la precipitación como de los campos de SST y SLP, se obtuvieron los correspondientes componentes principales (PC), los cuales corresponden a la variación temporal de los EOF. Posterior a obtener los PC, se estimó la correlación lineal entre los PC de precipitación y los PC de cada una de las potenciales variables explicativas. Este análisis se realizó a nivel estacional, pero diferenciando la información a escala mensual, es decir, se realizó el análisis contemplando el valor del PC de precipitación para un único mes. Adicionalmente, el análisis de correlación se llevó a

cabo considerando diferentes desfases temporales entre las variables, de manera que el PC de precipitación de un determinado mes se correlacionó con el valor del PC de las variables explicativas de meses anteriores. Esto último permite, a nivel de diagnóstico, evaluar la posible utilidad de una variable dentro de un modelo de regresión, tomando como base la magnitud de la correlación lineal con la variable dependiente del modelo. Sin embargo, es importante tener en cuenta que la correlación lineal de una variable predictora con la variable de respuesta no siempre es un indicador de que dicho predictor generará una mejora en la habilidad predictiva del modelo al ser agregado a éste, por lo que las correlaciones deben considerarse como un análisis inicial.

Los desfases contemplados para el análisis de correlación cruzada entre variables abarcaron hasta un máximo de 7 meses, lo que implica en términos de pronóstico, disponer de una ventana temporal de hasta 6 meses. Este límite se estableció con base en estudios previos, específicamente los que se enfocaron en el análisis del primer máximo de lluvia que ocurre en la vertiente pacífica de América Central, en los meses de mayo – junio (Maldonado et al., 2017; Alfaro et al., 2017).

Para el caso del modo pacífico (PC 2), el análisis de correlación cruzada se realizó para el período comprendido entre mayo y octubre, correspondiente a la época lluviosa. Para el modo caribe (PC 1), dado que no existe una época lluviosa definida y considerando que ha sido un régimen de precipitación poco estudiado en trabajos anteriores, se realizó el mismo análisis contemplando los 12 meses del año. En la Tabla 3-1 y en la Tabla 3-2 se detallan las mayores correlaciones de cada uno de los modos de precipitación para los diferentes meses analizados. La significancia estadística de las correlaciones encontradas se determinó con la prueba T-Student (Walpole et al., 2011), a partir de la cual se estableció que todas las correlaciones detalladas en la Tabla 3-1 y en la Tabla 3-2 son estadísticamente significativas, para un nivel de significancia de 0,05.

Para cada mes de cada uno de los modos analizados se detalla el nivel de correlación, la variable explicativa con la cual se presenta dicha correlación y el desfase temporal correspondiente. Es importante mencionar que el nombre de las variables que aparecen en

la Tabla 3-1 y en la Tabla 3-2 está en función de la variable original de la cual proviene y del número de EOF correspondiente, según la cantidad de varianza que explica, siendo el primero el que explica un mayor porcentaje de la varianza. Por ejemplo, para el caso del modo caribe en julio, los valores que presentan una mayor correlación lineal corresponden a los de abril del séptimo EOF de la SST.

Tabla 3-1: Máximas correlaciones lineales del modo caribe para cada mes

<i>Mes</i>	<i>Máxima correlación</i>	<i>Variable</i>	<i>Desfase (meses)</i>
<i>Enero</i>	-0,50	SLP 21	7
<i>Febrero</i>	-0,47	SLP 3	2
<i>Marzo</i>	0,51	SLP 5	2
<i>Abril</i>	0,43	SST 16	5
<i>Mayo</i>	0,49	SLP 13	1
<i>Junio</i>	0,46	SLP 9	7
<i>Julio</i>	0,63	SST 7	3
<i>Agosto</i>	-0,57	SST 11	2
<i>Septiembre</i>	-0,71	SST 2	7
<i>Octubre</i>	-0,68	SLP 1	4
<i>Noviembre</i>	0,62	SST 20	2
<i>Diciembre</i>	-0,55	SLP 17	1

Tabla 3-2: Máximas correlaciones lineales del modo pacífico para cada mes

<i>Mes</i>	<i>Máxima correlación</i>	<i>Variable</i>	<i>Desfase (meses)</i>
<i>Mayo</i>	0,52	SLP 21	4
<i>Junio</i>	-0,56	SLP 15	7
<i>Julio</i>	-0,57	SST 8	5
<i>Agosto</i>	0,60	SST 1	1
<i>Septiembre</i>	0,53	SST 1	1
<i>Octubre</i>	0,47	SST 24	1

Los resultados de la Tabla 3-1 y Tabla 3-2 muestran que las correlaciones encontradas son en general altas, y las variables a partir de las cuales se obtienen dichas correlaciones varían de mes a mes y entre modos. Esto implica que para la construcción de los modelos de regresión es necesario igualmente considerar los EOF retenidos a partir de los campos de SST y SLP, ya que la precipitación, tanto del pacífico como del caribe, podría ser

explicada a partir de diferentes patrones térmicos y de presión de los océanos circundantes, y no solo a partir de los primeros modos de variabilidad de SST y SLP. Otra característica importante de los resultados de correlación cruzada son los desfases en los cuales se presentan las mayores correlaciones, ya que para aproximadamente la mitad de los meses analizados (incluyendo ambos modos) se obtuvieron desfases temporales iguales o mayores a 4 meses, lo que, en términos de pronóstico, representa una importante antelación.

Entre ambos modos de precipitación también se observan contrastes importantes. Para el modo pacífico se observa que para los meses de agosto, septiembre y octubre la mayor correlación se presenta para un desfase de 1 mes y específicamente para los meses de agosto y septiembre se presenta con el mismo EOF, en este caso ENOS. Estos resultados respaldan el hecho de tratar estos tres meses en un solo grupo, correspondiente al segundo máximo de precipitación del modo pacífico, tal como se ha hecho en estudios anteriores (Spence et al, 2004, Alfaro, 2007; Fallas y Alfaro, 2012; Maldonado et al, 2013). Sin embargo, para el caso del primer máximo de precipitación, correspondiente a los meses de mayo y junio, no existe similitud entre las variables de mayor correlación ni el desfase donde se presenta dicha correlación. Este resultado justifica la construcción de modelos de regresión mes a mes, de manera que se pueda investigar más en detalle las variables que explican la precipitación y el potencial de pronóstico para estos primeros dos meses de la época lluviosa.

Para el modo caribe, contrario al modo pacífico, se presentan una mayor heterogeneidad en las variables y en los desfases asociados a las correlaciones más altas. Por lo tanto, se considera igualmente apropiado realizar los análisis y construcción de los modelos de regresión de manera individual para cada mes. Los resultados de la Tabla 3-1 muestran que, para el período comprendido entre diciembre y marzo, las variables que mejor correlacionan corresponden a los patrones de presión, lo cual es congruente con el hecho de que la precipitación en esos meses es producto de la intrusión de vientos provenientes

del norte del continente, debido a altos gradientes de presión meridionales (Waylen et al, 1996).

Con el objetivo de comparar los niveles de correlación obtenidos en la Tabla 3-1 y de la Tabla 3-2, se llevó a cabo el mismo análisis de correlación temporal, pero entre los modos de precipitación y algunos índices oceánicos y atmosféricos que se consideraron que podrían presentar una alta correlación con los principales modos de precipitación de Costa Rica (Anexo A4). La conclusión principal es que los modos de precipitación de Costa Rica presentan una mayor correlación con los diferentes EOF de SST y SLP considerados en el presente estudio que con índices oceánicos y atmosféricos preestablecidos. Esto es un indicador de que es posible explicar, o inclusive pronosticar de una mejor manera, la precipitación estacional de Costa Rica analizando patrones de SST y SLP de diferentes regiones, en vez de limitarse solamente a las regiones definidas por los índices.

3.4 Predictibilidad de la precipitación estacional

El análisis de la predictibilidad de la precipitación estacional en Costa Rica, diferenciada a nivel mensual, se llevó a cabo por medio de la generación de modelos de regresión, tanto para el modo caribe como para el modo pacífico. Por medio de dichos modelos se analizó, no solo la predictibilidad de la precipitación, sino también los predictores asociados a dicha predictibilidad, de manera que se pueda establecer cuáles patrones térmicos y de presión tienen realmente una influencia significativa en la precipitación estacional de Costa Rica.

Como potenciales predictores se contó con los primeros 27 EOF del campo de SST y los primeros 22 EOF del campo de SLP (i.e. 49 variables como potenciales predictores). Como variables de respuesta se consideraron solamente los primeros 2 EOF del campo de precipitación, el modo caribe (EOF 1) y el modo pacífico (EOF 2), debido a que a partir de ambos EOF es posible explicar el 58% de la variabilidad del campo de la precipitación.

Se consideraron 7 distintos desfases temporales del grupo de potenciales predictores (i.e. desfases entre 1 y 7 meses), de manera que se contemplara, como máximo, una ventana

de pronóstico de 6 meses. Todo esto se realizó para cada uno de los meses considerados en el análisis de correlación cruzada, siendo para el modo caribe los 12 meses del año, mientras que para el modo pacífico solamente los meses de la época lluviosa, es decir entre mayo y octubre. Por lo tanto, se consideraron un total de 126 modelos de regresión lineal. Del período para la calibración y validación de los modelos, el cual abarcó los primeros 36 años (datos) de la información de precipitación disponible (1980 – 2015), se utilizaron 30 años para el grupo de calibración y entrenamiento de los modelos y 6 años para el grupo de validación, con el objetivo de evitar un sobre ajuste de la habilidad predictiva de los modelos.

Haciendo uso del procedimiento combinado de selección de predictores progresiva hacia adelante (James et al., 2000) y el método de validación cruzada de Monte Carlo (Xu et al., 2004) se determinaron los predictores de los modelos de regresión que producían el menor error de validación cruzada ($RMSE_{CV}$). Debido a la aleatoriedad con la que el método de validación cruzada genera los grupos de calibración y validación, y dada la gran cantidad de posibles combinaciones que se pueden llevar a cabo (cerca a 2×10^6), la estimación del $RMSE_{CV}$, cada vez que se consideraba un nuevo predictor, se realizaba a partir de 10.000 iteraciones, con el objetivo de mapear la incertidumbre en la habilidad predictiva de los modelos (Lloyd-Hughes y Saunders, 2002). Esto permitió también evidenciar la variabilidad de los coeficientes de los predictores dentro del modelo, lo cual sirve para evaluar su estabilidad.

El proceso de construcción del modelo de cada mes, para cada desfase, se repitió 20 veces, con el propósito de evaluar si en cada repetición del proceso se seleccionaba el mismo set de predictores. La frecuencia con la que se presentaba el mismo set de predictores se consideró como una medida de la estabilidad del set de predictores del modelo final, el cual correspondía al modelo más frecuente. De esta manera, solo se consideraron los grupos de predictores que se presentaban en al menos 80% de las repeticiones del proceso de construcción del modelo, es decir, en 16 de las 20 veces que se repetía el proceso.

3.4.1 Modo caribe

Para el caso del modo caribe, para el primer semestre del año, se obtuvieron en general valores de $RMSE_{CV}$ iguales o superiores a 0,90 para los diferentes desfases considerados, lo que implica un bajo potencial predictivo de esos modelos, ya que solamente representan, en los mejores casos, una mejoría de un 10% con respecto a la climatología. Esto implica que la precipitación del caribe en Costa Rica durante el primer semestre no pareciera tener una relación lineal con patrones anteriores de SST y SLP, por lo que sería necesario analizar otras variables predictivas, tal vez a una escala más local, o considerar relaciones no lineales. Por lo tanto, para efectos de la evaluación de la habilidad de pronóstico real del modo caribe, usando los datos del período 2016 – 2019, se decidió enfocarse en los modelos desarrollados para la segunda mitad del año.

Para el segundo semestre, los modelos construidos para cada mes muestran una potencial habilidad predictiva mayor que los del primer semestre. Esta habilidad presenta a su vez un comportamiento variable según el mes y el desfase de los predictores. En la Figura 3-6 se muestra el valor del $RMSE_{CV}$ para cada uno de los meses del segundo semestre del año y para cada uno de los desfases considerados. Es importante tener en cuenta que cada uno de los puntos (desfase, mes) de las curvas de la Figura 3-6 representa un modelo diferente y no un mismo modelo con diferentes desfases en su campo de predictores. Por lo tanto, la Figura 3-6 ilustra la habilidad predictiva potencial existente para el pronóstico de la precipitación de cada mes, tomando en consideración las diferentes variables predictoras disponibles. Como complemento a esto, en la Tabla 3-3 se pueden ver los predictores que conforman los diferentes modelos, según el desfase y mes correspondiente, así como el valor numérico del $RMSE_{CV}$ asociado.

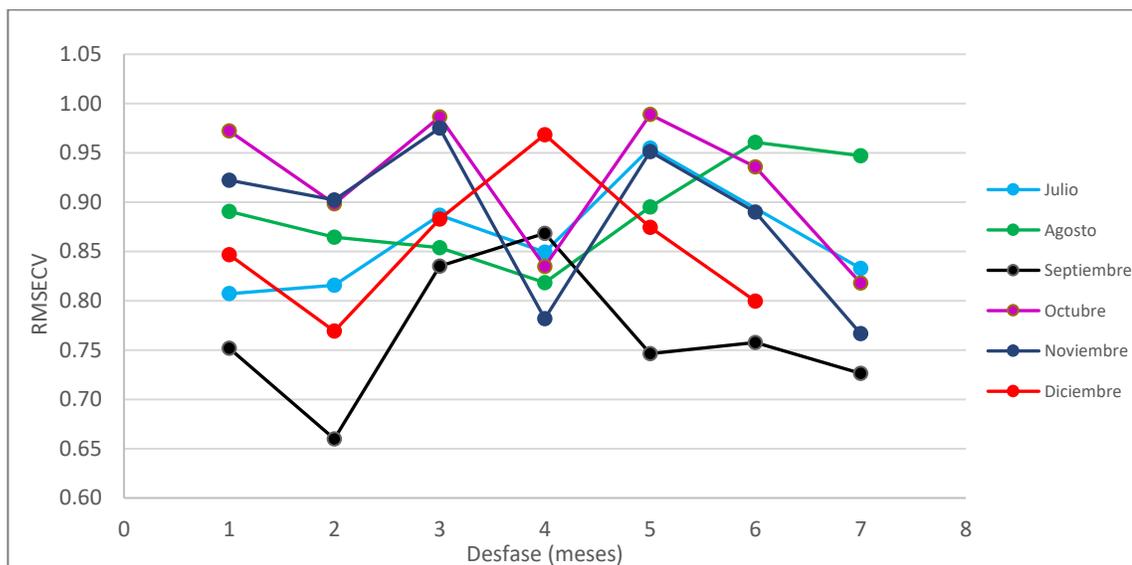


Figura 3-6: Variabilidad de la habilidad predictiva según el mes y el desfase considerado para el modo caribe

Considerando valores de $RMSE_{CV}$ iguales o menores a 0,85, se puede ver que para cada mes se podría disponer de una ventana temporal de al menos un mes (asociado a un desfase de 2 meses) para pronosticar la precipitación. Para el mes de julio, se puede observar que la mayor habilidad predictiva se presenta para los desfases de 1, 2 y 7 meses. Para agosto, el modelo que contempla un desfase de 4 meses en sus predictores es el que presenta la mayor habilidad predictiva, con un valor del $RMSE_{CV}$ igual a 0,82. Para los meses de septiembre y diciembre se presenta un comportamiento similar, donde los valores más bajos del $RMSE_{CV}$ se presentan en los desfases de 2 y 7 meses para septiembre y en los desfases de 2 y 6 meses para diciembre. Los meses de octubre y noviembre presentan entre ellos también una variación similar en el $RMSE_{CV}$. Para estos dos meses los valores más bajos del $RMSE_{CV}$ se exhiben para desfases de 4 y 7 meses, siendo menores para el desfase de 7 meses. Estos resultados representan una ventaja en términos de pronóstico, en especial para el caso del desfase de 7 meses, la cual implicaría una ventana temporal de 6 meses.

Los modelos para el mes de septiembre presentan en particular dos características importantes. La primera es que en general, pareciera ser el mes más pronosticable, ya que presenta los valores de $RMSE_{CV}$ más bajos, con valores iguales o menores a 0,75 para 5 de los 7 desfases considerados. Esto implica que en teoría dichos modelos tienen una habilidad predictiva con una superioridad de hasta 25% más que el caso en el que se considere solo la climatología. La otra característica es que, en 6 de los 7 modelos, el principal predictor es el segundo EOF de la SST (SST2), siendo la única excepción el modelo que considera un desfase de dos meses en sus predictores (ver Tabla 3-3). Esto implica que SST2 efectivamente representa un modulador de la precipitación del modo caribe durante el mes de septiembre, con la particularidad que su efecto presenta una inercia significativa, ya que se presenta para diferentes desfases, en especial para los más extensos. En la Figura 3-7 se observa el comportamiento espacial del SST2, la cual muestra que este modo de variabilidad se caracteriza por un contraste de la temperatura superficial del mar entre el sector oriental del pacífico tropical, cercano a las costas de Ecuador y Perú, y el sector ubicado en las cercanías de la costa pacífica de México, a la altura de la península de Baja California. Esto implica que la precipitación del mes de septiembre para el modo caribe, está influenciada principalmente por patrones térmicos en el océano Pacífico y no en el mar Caribe u en el océano Atlántico.

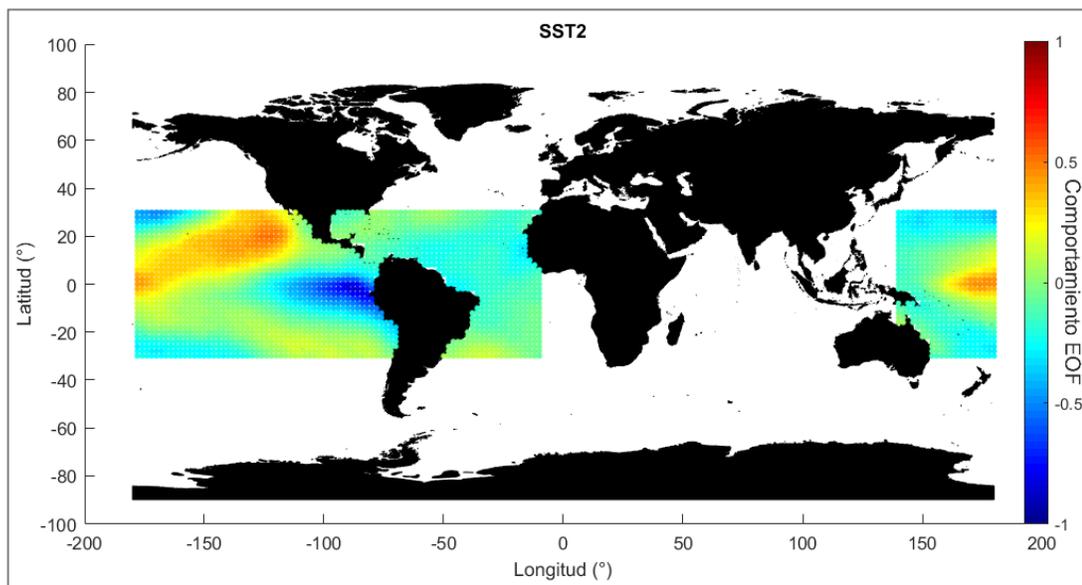


Figura 3-7: Comportamiento espacial del segundo EOF de la SST

Un aspecto importante de recalcar para el caso de los meses analizados para el modo caribe, es la heterogeneidad en los predictores seleccionados para cada modelo, por lo que la decisión de separar los modelos para cada mes se considera apropiada. Basándose en los predictores, en términos generales, se puede establecer que la precipitación de julio, agosto, septiembre y noviembre está en función principalmente de patrones térmicos anteriores a los meses de precipitación, mientras que la precipitación de los meses de octubre y diciembre se encuentra modulada por patrones de presión, tal como se observa en la Tabla 3-3.

En general, para la precipitación del modo caribe, durante el segundo semestre del año, existe una potencial habilidad predictiva para desfases de al menos 4 meses, lo cual implica una ventana temporal de pronóstico amplia. Esto último tendría una repercusión positiva en términos de la prevención y mitigación de las posibles afectaciones que tiene la precipitación en la vertiente caribe de Costa Rica, tales como las inundaciones, las cuales a su vez tienen efecto en el sector productivo y social de la región.

Tabla 3-3: Predictores de los modelos de regresión generados para el modo caribe

<i>Mes</i>	<i>Desfase</i>	<i>Predictores</i>				<i>RMSE_{CV}</i>
<i>Julio</i>	1	SST5	SST1			0,81
	2	SST5	SST1	SST16	SST7	0,82
	3	SST7				0,89
	4	SST7	SLP19	SLP4		0,85
	5	SST7				0,95
	7	SST7	SLP13	SST2	SLP11	0,83
<i>Agosto</i>	1	SST11	SST1			0,89
	2	SST11	SST22			0,86
	3	SLP8				0,85
	4	SST7	SST22	SST1		0,82
	5	SST27	SST7			0,90
	6	SST14	SST7			0,96
	7	SST23	SST16			0,95
<i>Septiembre</i>	1	SST2	SLP15			0,75
	2	SLP15	SST26	SLP4	SST19	0,66
	3	SST2	SLP6	SST19	SLP15	0,84
	4	SST2	SLP14			0,87
	5	SST2	SLP7	SST27		0,75
	6	SST2	SLP2	SST27		0,76
	7	SST2	SST27			0,73
<i>Octubre</i>	1	SLP20				0,97
	2	SST11	SST3	SST2	SLP8	0,90
	3	SLP13				0,99
	4	SLP1				0,83
	5	SLP6	SST15			0,99
	6	SLP16	SST7			0,94
	7	SLP15	SLP14	SST12	SLP8	0,82
<i>Noviembre</i>	1	SST20	SST6			0,92
	2	SST20				0,90
	3	SLP1				0,98
	4	SST4	SST5	SST2	SLP19	0,78
	5	SLP13				0,95
	6	SST15	SST19	SLP6	SST17	0,89
	7	SST20	SST2	SLP19	SST5	0,77
<i>Diciembre</i>	1	SLP17	SST25			0,85
	2	SLP5	SST25	SLP10	SST5	0,77
	3	SLP13	SST26	SST1	SST24	0,88
	4	SST9				0,97
	5	SLP8	SLP19	SST20		0,87
	6	SLP1	SLP3	SLP4		0,80

3.4.2 Modo Pacífico

Para el caso del modo pacífico se construyó un gráfico similar al de la Figura 3-6, en el cual se muestra la variabilidad del $RMSE_{CV}$, es decir, la habilidad predictiva potencial para cada mes, tomando en consideración las diferentes variables predictoras disponibles. Estos resultados se muestran en la Figura 3-8. Para este caso, los meses analizados fueron los que conforman la época lluviosa (mayo – octubre), ya que estos son los que tienen una mayor relevancia en términos de pronósticos operacionales, como consecuencia de la marcada estacionalidad que experimenta la vertiente pacífica de Costa Rica.

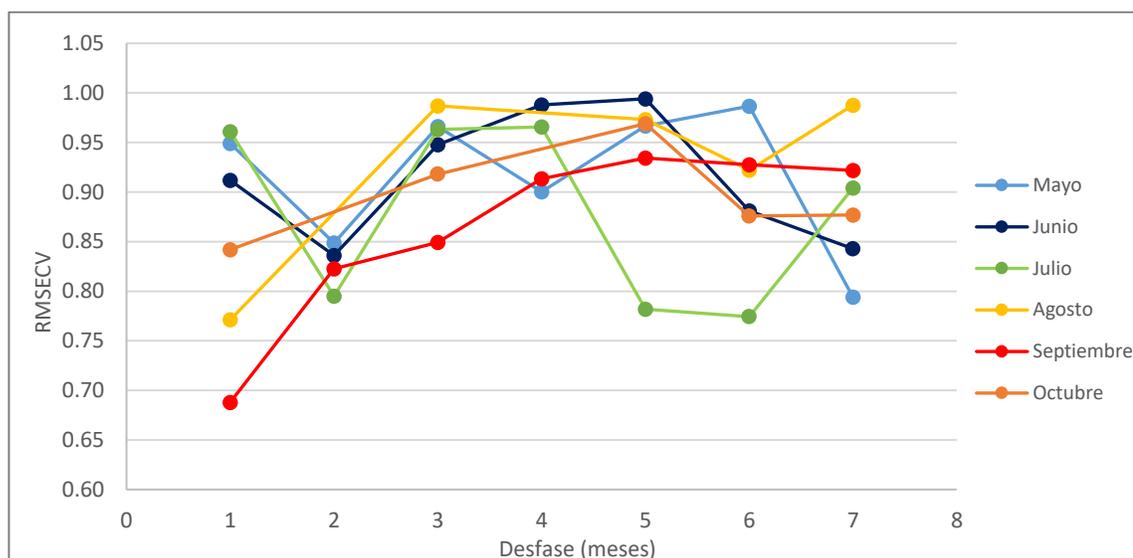


Figura 3-8: Variabilidad de la habilidad predictiva según el mes y el desfase considerado para el modo pacífico

A partir de la Figura 3-8 se puede observar que, en términos de la variabilidad del $RMSE_{CV}$, los meses analizados se podrían dividir en tres subperíodos: mayo – junio, julio y agosto – octubre. Esta división coincide con los períodos considerados en investigaciones previas según el comportamiento bimodal de la época lluviosa en la vertiente pacífica de América Central (Alfaro, 2007; Fallas y Alfaro, 2012; Maldonado et al, 2013).

Para los meses de mayo y junio, los valores más bajos de $RMSE_{CV}$ se presentan para los modelos correspondientes para los desfases de 2 y 7 meses, con valores entre 0,80 y 0,85, mientras que para los restantes desfases los valores son superiores a 0,90 o inclusive 0,95, lo que implica que estos últimos tienen una habilidad predictiva muy similar a la que se podría obtener a partir de solamente la climatología. Si bien los meses de mayo y junio muestran similitud en términos de los desfases donde tienen una mayor predictibilidad, los predictores de los modelos de dichos meses son diferentes, lo que demuestra que no sería apropiado tratarlos de manera conjunta. La principal diferencia es que la precipitación de mayo, según los predictores de los modelos para los desfases de 2 y 7 meses, responde principalmente a patrones de SST, mientras que para junio la precipitación está en función principalmente de anomalías de presión. Esto se puede observar en la Tabla 3-4, en la cual se muestran los predictores de los modelos de regresión generados para el modo pacífico.

Para el mes de julio, los desfases en los que se presentan los valores más bajos de $RMSE_{CV}$ corresponden a 2, 5 y 6 meses, para los cuales se presentan valores menores que para los meses de mayo y junio. Por lo tanto, la precipitación del mes de julio pareciera ser más pronosticable que la del bimestre anterior, en especial si se consideran los modelos correspondientes a los desfases de 5 y 6 meses.

Con respecto al período de agosto, septiembre y octubre (ASO), los tres meses coinciden en el hecho de que la mayor predictibilidad se obtiene con un desfase de apenas 1 mes, ya que para desfases mayores se presenta un claro aumento del valor de $RMSE_{CV}$. Adicionalmente, para los meses de agosto y septiembre el principal predictor de los modelos es el EOF 1 de SST, el cual representa, según lo mencionado en secciones anteriores, al fenómeno ENOS. Por su parte, para el mes de octubre, los predictores de los modelos corresponden principalmente a patrones de SLP, lo cual difiere de lo que se presenta para el bimestre anterior. Esto implica que la precipitación en octubre no se encuentra en función de los mismos mecanismos que para el caso de agosto y septiembre y que, por lo tanto, debería considerarse de manera separada.

Tabla 3-4: Predictores de los modelos de regresión generados para el modo pacífico

<i>Mes</i>	<i>Desfase</i>	<i>Predictores</i>				<i>RMSE_{CV}</i>
<i>Mayo</i>	1	SST1	SLP19			0,95
	2	SST22	SLP10			0,85
	3	SST22	SLP9			0,97
	4	SLP21	SLP12			0,90
	5	SST25				0,97
	6	SST5				0,99
	7	SST9	SST27	SLP3	SST19	0,79
<i>Junio</i>	1	SLP15	SST7			0,91
	2	SLP4	SLP8	SST17	SST15	0,84
	3	SLP4				0,95
	4	SST22				0,99
	5	SLP6				0,99
	6	SST27	SST2	SST14	SLP13	0,88
	7	SLP22	SST4	SLP1		0,84
<i>Julio</i>	1	SST5				0,96
	2	SST5	SLP6	SLP15	SST3	0,80
	3	SLP17				0,96
	4	SST24				0,97
	5	SST8	SLP14	SLP20	SLP5	0,78
	6	SST8	SST7	SST17	SLP22	0,77
	7	SLP1				0,90
<i>Agosto</i>	1	SST1	SST21	SST27		0,77
	3	SLP18				0,99
	5	SLP17	SLP7			0,97
	6	SST23	SST7			0,92
	7	SST23				0,99
<i>Septiembre</i>	1	SST1	SLP14	SLP16		0,69
	2	SST1	SLP5	SLP4		0,82
	3	SST18	SLP10	SLP15		0,85
	4	SST18				0,91
	5	SLP2				0,93
	6	SST7	SLP15			0,93
	7	SST13	SST7			0,92
<i>Octubre</i>	1	SLP10	SLP9	SST4		0,84
	3	SLP10	SST26	SST1		0,92
	5	SLP7				0,97
	6	SST7	SST10	SLP17		0,88
	7	SLP3	SST10	SST5	SST11	0,88

El hecho de que la precipitación de octubre esté en función de otras variables diferentes a la de los meses de agosto y septiembre representa un contraste con investigaciones anteriores, ya que los estudios previos se habían enfocado en la habilidad para pronosticar

ASO de manera agrupada, para el cual establecieron como principal predictor, la temperatura superficial del mar del mes de julio (Fallas y Alfaro, 2012; Maldonado et al., 2013). Esto es congruente con los resultados obtenidos en el presente trabajo para los meses de agosto y septiembre, pero no para el mes de octubre. Estas diferencias se pueden deber al efecto predominante que tiene ENOS (SST1), de manera separada, sobre la precipitación de agosto y septiembre, lo cual genera que cuando se considera de manera conjunta toda la precipitación del trimestre ASO, el efecto predominante siga siendo el de ENOS. Un resultado similar fue obtenido por Uvo et al. (1998) cuando analizaron la relación entre SST del Atlántico y del Pacífico Tropical y la precipitación (estacional y mensual) de la región noreste de Brasil. Estos autores mencionan que las correlaciones a nivel estacional resultan principalmente de las correlaciones más fuertes que se presentan a escala mensual. Esto implica que el análisis de la predictibilidad de la precipitación estacional variará en función de si ésta se realiza a escala mensual o agrupándola en bimestres o trimestres. Para el caso de los modos de precipitación considerados para Costa Rica, se considera apropiado realizar el análisis a escala mensual, debido a la heterogeneidad de los predictores resultantes en cada modelo, en especial para el caso del modo caribe.

Con respecto a la relación de ENOS con la precipitación de la época lluviosa del modo pacífico, en la Figura 3-9 se muestra la variación de la correlación entre el modo pacífico y SST1 para cada uno de los meses y desfases considerados. En dicha figura se puede observar como las mayores correlaciones se presentan para los meses de agosto y septiembre, en los desfases más pequeños, ya que conforme aumentan el desfase para esos meses las correlaciones se van haciendo cada vez más bajas. En octubre se presenta el mismo comportamiento que en los meses de agosto y septiembre, pero con correlaciones de menor magnitud. Para los restantes meses, las correlaciones son más bajas, en especial para el mes de julio, donde para ninguno de los desfases considerados existe una correlación significativa. Esto implica que, a pesar de la evidente relación que existe entre ENOS y la precipitación del modo pacífico, ENOS no es suficiente para explicar lo que ocurre durante toda la época lluviosa, en especial al inicio de ésta, donde las correlaciones

no son tan altas como para el período ASO. Adicionalmente, también se analizó la correlación de la variable SST1 con el modo caribe de precipitación, como complemento al análisis realizado para el modo pacífico. Para este segundo caso, las correlaciones presentan los mayores valores en los meses de julio y agosto, para los desfases menores, ya que para desfases mayores la correlación disminuye, similar a lo que ocurría para el modo pacífico.

Lo interesante de estos resultados es que pareciera ser que ENOS tiene un efecto desfasado con la precipitación de la vertiente caribe y la vertiente pacífica, ya que para el caribe la relación es más fuerte en los meses de julio y agosto, mientras que para el pacífico esto ocurre en los meses de agosto y septiembre. Sin embargo, a pesar de que la variable SST1 (asociada a ENOS) presenta una correlación estacional importante con la precipitación en ambas vertientes, su habilidad de pronóstico queda limitada a la precipitación del modo pacífico, específicamente a los meses de agosto y septiembre, ya que para los restantes casos no representa el principal predictor de los modelos, o bien ni siquiera forma parte del campo de predictores. Por lo tanto, un pronóstico de la precipitación estacional basado exclusivamente en el comportamiento de ENOS es insuficiente para la precipitación de Costa Rica y como consecuencia de esto es necesario recurrir a otras variables explicativas, tanto de SST como de SLP.

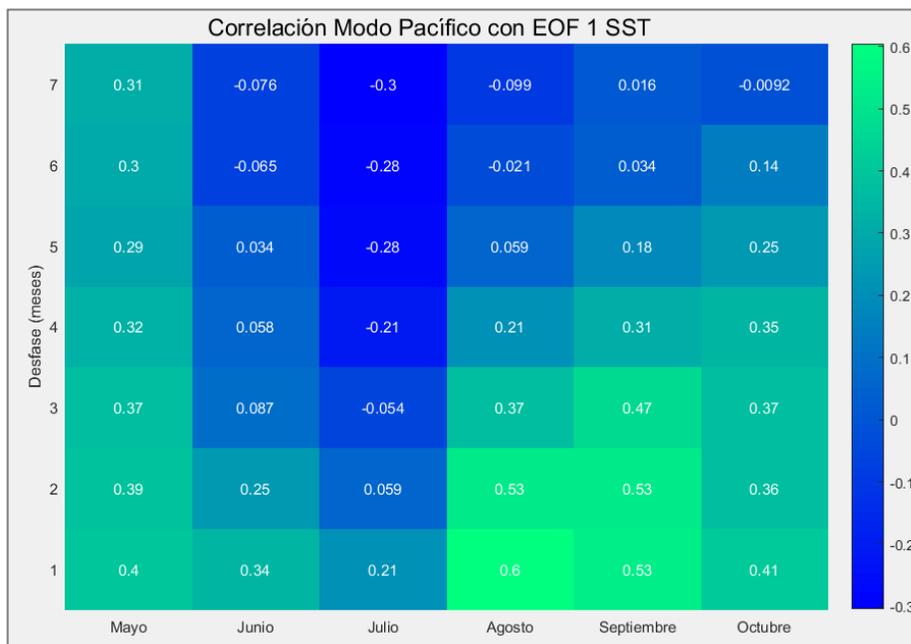


Figura 3-9: Variación temporal de la correlación entre el modo pacífico y SST1

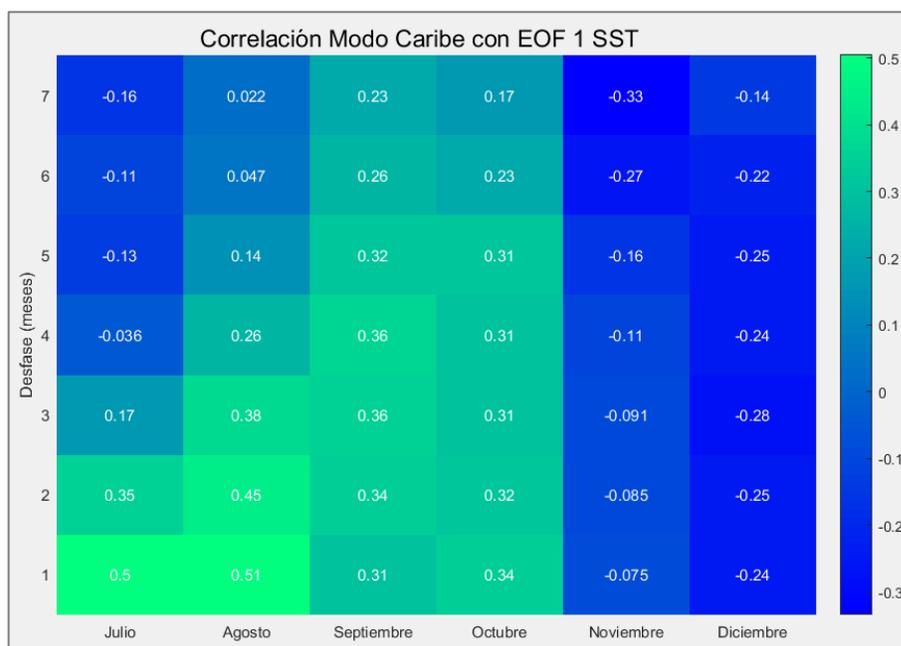


Figura 3-10: Variación temporal de la correlación entre el modo caribe y SST1

4 PRONÓSTICO DE LA PRECIPITACIÓN

4.1 Habilidad real de pronóstico

Los modelos de regresión a los cuales se les evaluó su habilidad real de pronóstico corresponden a los mejores modelos de cada uno de los meses analizados. Para abarcar y evaluar una mayor cantidad de modelos, se consideraron los modelos que presentaron un $RMSE_{CV}$ igual o menor a 0,85. De esta manera se evaluó un total de 28 modelos, tomando en consideración tanto los definidos para el modo caribe como para el modo pacífico, según lo que se observa en la Figura 3-6 y Figura 3-8.

Es importante tener en cuenta que los modelos de regresión tienen como variable dependiente un determinado modo de precipitación, es decir un componente principal de la precipitación, por lo que para realizar la comparación con los modelos de referencia fue necesario desagregar el componente principal pronosticado entre las estaciones meteorológicas consideradas, de manera que se pudiera disponer de un valor de precipitación estimada para cada estación.

Tomando en cuenta la clara diferencia que existe entre el modo caribe (EOF 1) y el modo pacífico (EOF 2) de la precipitación en Costa Rica, así como el análisis desagregado realizado para cada modo de precipitación a lo largo del informe, se realizó una separación espacial de las estaciones para evaluar la habilidad de pronóstico de los modelos de regresión. Para realizar dicha separación se consideró el comportamiento espacial de cada uno de los EOF de precipitación, observado en la Figura 3-1.

En la Figura 4-1 se observa la separación de las estaciones, según el modo de precipitación, de manera que el modo caribe abarca las regiones Caribe y Norte y el modo pacífico comprende las regiones Pacífico Norte, Pacífico Central, Pacífico Sur y Valle Central. Para este último modo hay una mayor cantidad de estaciones para evaluar el pronóstico.

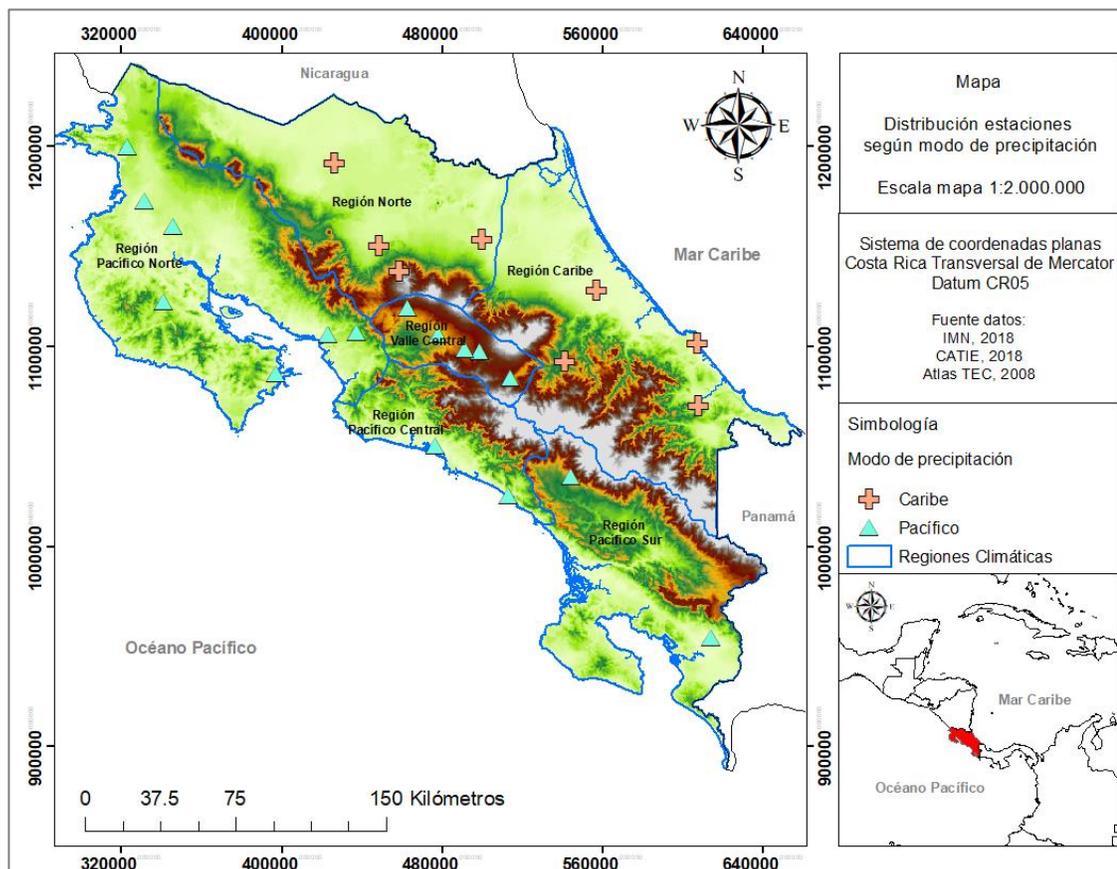


Figura 4-1: Separación de estaciones para pronóstico según el modo de precipitación

En la Figura 4-2 y en la Figura 4-3 se muestran los valores del RSR, para los casos del modo pacífico y caribe, respectivamente, considerando los mejores modelos de regresión para cada mes con respecto a los modelos de referencia. Adicionalmente, en la Tabla 4-1 y en la

Tabla 4-2 se muestran los valores numéricos del RSR y el desfase del campo de predictores de los modelos considerados para el modo pacífico y caribe, respectivamente. Dada la similitud entre el comportamiento del RAE y del RSR, las tablas referentes a los valores del RAE, así como los valores de Sesgo, no se muestran en la presente sección sino en el Anexo A5.

Para el modo pacífico se puede observar que el único modelo de regresión que supera los modelos de climatología y persistencia es el correspondiente al mes de mayo, ya que para los restantes meses se obtiene un mejor desempeño con los modelos de climatología o persistencia. Una cualidad importante que tiene el modelo del mes de mayo es la antelación con la cual se puede hacer la estimación de la precipitación mensual, ya que se podría disponer del pronóstico 6 meses antes del inicio del mes, dado que considera los valores del mes de octubre del año anterior. Esto representa una ventaja en términos operativos, ya que permite disponer de una ventana temporal lo suficientemente grande como para planificar acciones de mitigación previo a condiciones de precipitación anómalas. Esto es muy importante en la vertiente pacífica de Costa Rica, ya que es durante mayo que se da el inicio de la época lluviosa. Por lo tanto, conocer las condiciones de precipitación del primer mes de la época lluviosa, posterior a la época seca durante la cual las precipitaciones son mínimas, tiene una gran relevancia en sectores como la agricultura y la producción hidroeléctrica, los cuales tienen sus períodos más críticos al final de la época seca, donde la disponibilidad del recurso hídrico es menor.

Aunque el modelo de regresión correspondiente al mes de junio también tiene un valor de RSR superior al de los modelos de referencia, la diferencia es despreciable, de manera que no se puede argumentar que el modelo de regresión se desempeña mejor que los modelos de referencia. Para el caso de los meses de agosto y septiembre se presenta la particularidad de que el mejor modelo, en especial para el mes de agosto, es el modelo de persistencia, el cual para ambos meses considera las anomalías de precipitación del mes anterior. Esto implica un comportamiento autorregresivo de la precipitación durante el período pronosticado, donde parecieran ser más relevantes las condiciones de precipitación del mes anterior que los patrones térmicos y de presión. No obstante, aunque se considerara como variable predictora la precipitación del mes anterior, sigue presentándose la limitación de que para los meses de agosto y septiembre no se cuenta con una ventana de pronóstico adecuada, ya que el desfase de los predictores sería de apenas 1 mes.

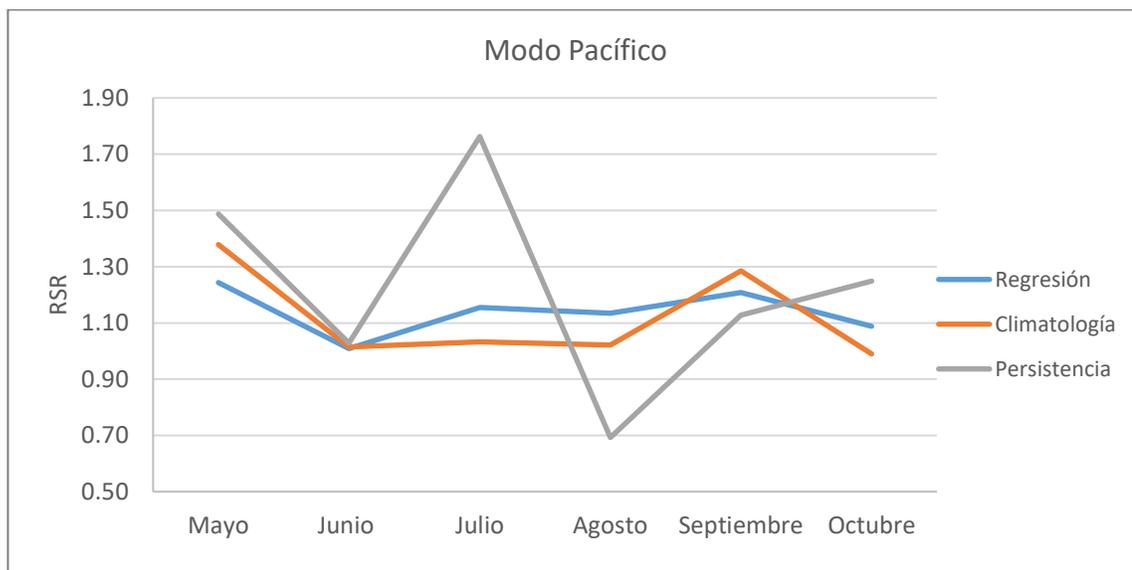


Figura 4-2: Comparación del RSR entre los modelos de regresión para el modo pacífico y los modelos de referencia

Tabla 4-1: RSR de los modelos de regresión y los modelos de referencia del modo pacífico

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Mayo</i>	1,24	1,38	1,49	7
<i>Junio</i>	1,01	1,02	1,03	2
<i>Julio</i>	1,16	1,03	1,76	2
<i>Agosto</i>	1,13	1,02	0,69	1
<i>Septiembre</i>	1,21	1,29	1,13	1
<i>Octubre</i>	1,09	0,99	1,25	1

Para el caso del modo caribe, los meses en los que los modelos de regresión presentan una habilidad de pronóstico superior a los modelos de referencia son julio, agosto y septiembre, siendo el primero el que más sobresale con respecto a los modelos de referencia. El mes de julio en la vertiente caribe es, en promedio, uno de los meses más lluviosos, siendo superado solamente por diciembre, por lo que, en términos de pronóstico, es relevante conocer las condiciones de la precipitación mensual durante dicho mes. Para este caso, el correspondiente modelo de regresión genera el pronóstico de precipitación

con una antelación de 1 mes, ya que los predictores se basan en patrones térmicos desarrollados durante el mes de mayo.

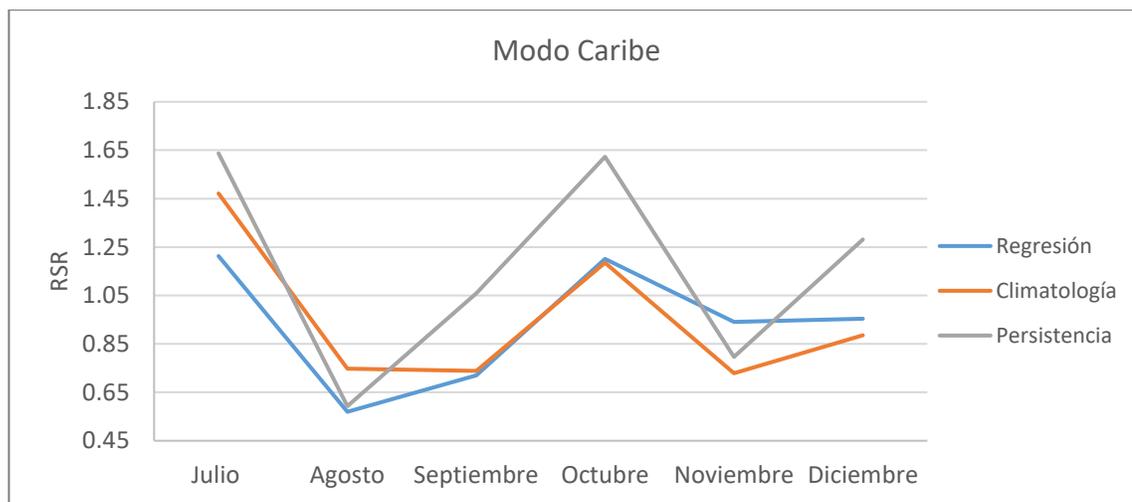


Figura 4-3: Comparación del RSR entre los modelos de regresión para el modo caribe y los modelos de referencia

Tabla 4-2: RSR de los modelos de regresión y los modelos de referencia del modo caribe

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Julio</i>	1,21	1,47	1,64	2
<i>Agosto</i>	0,57	0,75	0,59	4
<i>Septiembre</i>	0,72	0,74	1,06	5
<i>Octubre</i>	1,20	1,18	1,62	4
<i>Noviembre</i>	0,94	0,73	0,80	7
<i>Diciembre</i>	0,95	0,89	1,28	2

Los modelos de regresión construidos para los meses de agosto y septiembre, si bien no presentan una ganancia de pronóstico relevante con respecto a los modelos de referencia, corresponden a los modelos de regresión con la mejor habilidad predictiva, ya que presentan los valores más bajos de RSR. En este caso los valores de RSR menores a 1 indican que las estimaciones de los modelos de regresión son cercanas a la precipitación mensual registrada en las estaciones de la vertiente caribe, sin embargo, una habilidad

similar también alcanza para ambos meses a partir de los modelos de referencia. En el caso de los modelos de climatología, esto se debe al hecho de que, en general, la precipitación registrada en las estaciones consideradas en los meses de agosto y septiembre del período pronosticado se mantuvo relativamente cercana a la precipitación promedio. Este comportamiento de la precipitación es bastante claro para el mes de septiembre, tal como se puede ver en la Figura 4-4. En dicha figura los puntos de colores representan la precipitación registrada en el mes de septiembre en las estaciones del caribe durante el período 2016 – 2019, la línea roja discontinua representa la variación de la precipitación promedio de septiembre entre las estaciones y las líneas horizontales definen los límites de una desviación estándar con respecto al promedio para cada estación.

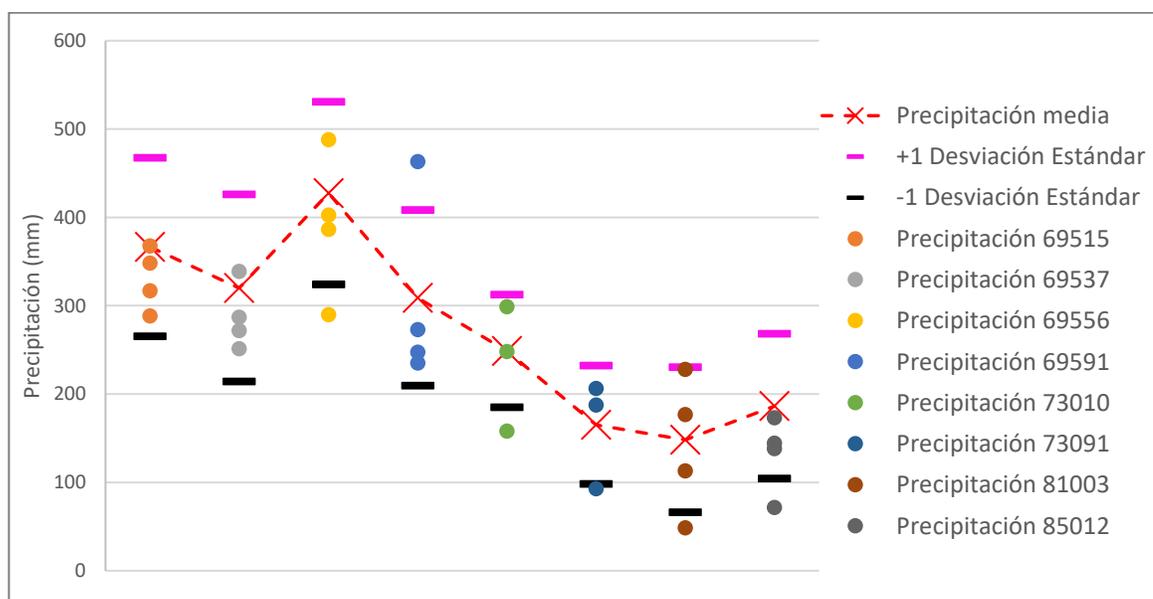


Figura 4-4: Comparación de la precipitación registrada en septiembre en las estaciones del Caribe en el período 2016 – 2019

Lo que se observa en la Figura 4-4 es que la potencial mejora en términos de pronóstico que pueda tener el modelo de regresión por encima del modelo de climatología no puede apreciarse con los datos disponibles, debido a lo cercano de éstos con la precipitación media de cada estación. Sin embargo, con base en el análisis de validación cruzada realizado en el capítulo anterior (Figura 3-6), lo esperable es que el modelo de regresión

para el mes de septiembre presente una habilidad real de pronóstico superior al modelo de climatología.

Una condición similar a la de septiembre se presenta para el caso de los meses de noviembre y diciembre; sin embargo, en estos casos los modelos de regresión no tienen una habilidad predictiva tan significativa como en agosto y septiembre. Adicionalmente, en los meses de noviembre y diciembre hay una mayor cantidad de datos faltantes, por lo que el análisis se decidió enfocar principalmente en los primeros tres meses (julio-agosto-septiembre).

Otro aspecto a resaltar para el modo caribe es lo que ocurre en los meses de agosto y noviembre, para los cuales el modelo de persistencia presenta valores de RSR bajos. Lo interesante es que para ambos casos el pronóstico de la precipitación se encuentra en función de las anomalías de precipitación que se presentan en el mes de abril, ya que los desfases considerados son 4 y 7 meses, para agosto y noviembre, respectivamente. Por lo tanto, pareciera ser relevante para futuros estudios, investigar más en detalle la relación entre las anomalías de precipitación que se presentan en abril con el comportamiento de las anomalías en los meses de agosto y noviembre y evaluar si agregando información autorregresiva, se podría tener una mejora en la habilidad de pronóstico de los presentes modelos de regresión.

4.2 Análisis de los modelos de regresión para pronóstico

Tomando en cuenta los resultados de la sección anterior, se realizó un análisis más detallado de algunos de los modelos de regresión y de los pronósticos realizados con dichos modelos. Esto último se explica en detalle en las últimas dos secciones del presente capítulo.

Para el modo pacífico, se consideró solamente el modelo para la precipitación de mayo, llamado de aquí en adelante modelo Mayo-Pacífico, ya que éste representa el único modelo donde se observa una superioridad en la habilidad de pronóstico con respecto a los modelos de referencia. En la Tabla 4-3 se muestra esta superioridad al comparar la

habilidad de pronóstico del modelo de regresión versus los modelos de referencia a partir de las tres métricas continuas utilizadas. Adicionalmente, este modelo de regresión tiene la característica de realizar el pronóstico con una antelación de 6 meses.

Tabla 4-3: Desempeño del modelo Mayo-Pacífico a partir de las métricas continuas

<i>Modelo</i>	<i>RSR</i>	<i>RAE</i>	<i>BIAS</i>
<i>Regresión</i>	1,24	1,29	35,3
<i>Climatología</i>	1,37	1,43	89,8
<i>Persistencia</i>	1,49	1,56	21,7

Para el modo caribe, se consideraron los modelos de regresión para julio, agosto y septiembre, llamados desde ahora Julio-Caribe, Agosto-Caribe y Septiembre-Caribe, respectivamente. El modelo Julio-Caribe demostró ser un modelo superior a los modelos de referencia, por lo tanto, representa una mejora en términos de pronóstico. El caso de los meses de agosto y septiembre se debe a que los correspondientes modelos tienen la mejor habilidad de pronóstico según los análisis realizados, ya que no solo demostraron un desempeño levemente mejor que los modelos de referencia, sino que los valores de las métricas de desempeño utilizadas corresponden a los valores más bajos registrados. Esto último se detalla en la Tabla 4-4.

Tabla 4-4: Desempeño de los modelos para el modo caribe a partir de las métricas continuas

<i>Julio</i>			
<i>Modelo</i>	<i>RSR</i>	<i>RAE</i>	<i>BIAS</i>
<i>Regresión</i>	1,21	1,22	26,4
<i>Climatología</i>	1,47	1,33	93,7
<i>Persistencia</i>	1,64	1,65	93,9
<i>Agosto</i>			
<i>Modelo</i>	<i>RSR</i>	<i>RAE</i>	<i>BIAS</i>
<i>Regresión</i>	0,57	0,57	44,5
<i>Climatología</i>	0,75	0,79	-36,3
<i>Persistencia</i>	0,59	0,59	-1,70
<i>Septiembre</i>			
<i>Modelo</i>	<i>RSR</i>	<i>RAE</i>	<i>BIAS</i>
<i>Regresión</i>	0,72	0,73	-16,27
<i>Climatología</i>	0,74	0,77	-23,4
<i>Persistencia</i>	1,06	1,08	13,8

Para cada uno de los cuatro modelos de regresión mencionados, se realizó un análisis de la significancia estadística de los modelos y de cada una de las variables predictoras que los conforman. Adicionalmente, se verificaron los supuestos que deben cumplir dichos modelos según el ajuste generado a partir del método mínimos cuadrados ordinarios, para la obtención de los estimadores insesgados de mínima varianza.

De la Tabla 4-5 a la Tabla 4-8 se muestra el análisis de significancia estadística de cada uno de los coeficientes de los modelos, además el RMSE (normalizado por la climatología) y el coeficiente de determinación (R^2) y el R^2 ajustado, como métricas del ajuste del modelo con los datos observados. El detalle de los análisis de varianza de los modelos de regresión se muestra en el Anexo A6, donde para cada uno de los cuatro modelos se construyó la correspondiente tabla ANOVA.

Tabla 4-5: Significancia estadística de los coeficientes del modelo Mayo-Pacífico

<i>Variable</i>	<i>Coficiente</i>	<i>Valor Dist. T-Student</i>	<i>Valor p</i>	<i>Variabilidad coeficiente</i>
<i>SST9</i>	0,391	3,43	$1,72 \times 10^{-3}$	0,0533
<i>SST27</i>	0,598	5,05	$1,87 \times 10^{-5}$	0,0708
<i>SLP3</i>	-0,302	-2,46	$1,96 \times 10^{-2}$	0,0472
<i>SST19</i>	0,226	1,91	$6,56 \times 10^{-2}$	0,0467

RMSE_{normalizado} = 0,634

$R^2 = 0,598$

R^2 ajustado = 0,559

Tabla 4-6: Significancia estadística de los coeficientes del modelo Julio-Caribe

<i>Variable</i>	<i>Coficiente</i>	<i>Valor Dist. T-Student</i>	<i>Valor p</i>	<i>Variabilidad coeficiente</i>
<i>SST5</i>	0,309	2,57	$1,48 \times 10^{-2}$	0,0492
<i>SST1</i>	0,530	4,05	$3,05 \times 10^{-4}$	0,0599
<i>SST16</i>	-0,257	-2,13	$4,12 \times 10^{-2}$	0,0472
<i>SST7</i>	0,378	2,82	$8,11 \times 10^{-3}$	0,0647

RMSE_{normalizado} = 0,680

$R^2 = 0,538$

R^2 ajustado = 0,495

Tabla 4-7: Significancia estadística de los coeficientes del modelo Agosto-Caribe

<i>Variable</i>	<i>Coficiente</i>	<i>Valor Dist. T-Student</i>	<i>Valor p</i>	<i>Variabilidad coeficiente</i>
<i>SST7</i>	0,474	3,74	$6,87 \times 10^{-4}$	0,0775
<i>SST22</i>	0,367	2,86	$7,28 \times 10^{-3}$	0,0476
<i>SST1</i>	0,351	2,71	$1,05 \times 10^{-2}$	0,0545

$$RMSE_{\text{normalizado}} = 0,727$$

$$R^2 = 0,472$$

$$R^2 \text{ ajustado} = 0,440$$

Tabla 4-8: Significancia estadística de los coeficientes del modelo Septiembre-Caribe

<i>Variable</i>	<i>Coficiente</i>	<i>Valor Dist. T-Student</i>	<i>Valor p</i>	<i>Variabilidad coeficiente</i>
<i>SST2</i>	-0,571	-5,36	$6,40 \times 10^{-6}$	0,0556
<i>SLP7</i>	0,439	4,05	$2,93 \times 10^{-4}$	0,0571
<i>SST27</i>	-0,340	-3,18	$3,20 \times 10^{-3}$	0,0550

$$RMSE_{\text{normalizado}} = 0,612$$

$$R^2 = 0,626$$

$$R^2 \text{ ajustado} = 0,603$$

A partir de los resultados anteriores se observa que la totalidad de los predictores de los modelos para el pronóstico del modo caribe son estadísticamente significativos, para un nivel de confianza del 95%. Para el caso del modelo Mayo-Pacífico, el cuarto predictor, SST19, presenta un valor p superior a 0,05, por lo tanto, no hay suficiente evidencia estadística para rechazar la hipótesis nula ($\beta_i = 0$). Sin embargo, tomando en cuenta que el valor es cercano a 0,05, se consideró mantener dicho predictor como parte de las variables independientes del modelo de regresión. Adicional a la significancia estadística de los predictores, se determinó la variabilidad que tienen sus coeficientes. Esta variabilidad corresponde a la desviación estándar de los valores de los coeficientes obtenidos a partir de las múltiples iteraciones que se realizaron dentro del proceso de validación cruzada de los modelos, explicado en el capítulo anterior. Determinar dicha variabilidad es importante debido a que los coeficientes del modelo representan el efecto de cada uno de los predictores en la variable de respuesta. Por lo tanto, es necesario cuantificar la variabilidad de los predictores para evaluar si corresponden a predictores estables, es decir, independientemente de los valores utilizados para entrenar y validar el

modelo, siempre presenten el mismo signo dentro del modelo. Con base en los valores que se detallan en las tablas anteriores, se puede observar que, aun considerando tres desviaciones estándar, el signo de los coeficientes de los modelos no varía, es decir, el tipo de efecto de los predictores sobre las variables de respuesta es el mismo y por lo tanto se pueden considerar predictores estables.

Con respecto a las métricas de ajuste, específicamente el RMSE, se puede ver una importante mejoría si se compara con el valor de RMSE obtenido durante el proceso de validación cruzada ($RMSE_{CV}$). Esto se debe a que el RMSE se calcula a partir de una validación del modelo que se hace sobre los mismos datos a partir de los cuales se entrenó el modelo (la totalidad de los datos), por lo que en dicha validación no se está poniendo a prueba la capacidad predictora del modelo. Debido a esto el RMSE es un indicador de una habilidad falsa por parte del modelo, por lo que debe utilizarse solamente como una medida del ajuste del modelo a los datos observados.

Con el objetivo de verificar los supuestos implícitos en el ajuste por mínimos cuadrados ordinarios de los modelos de regresión, se analizó el comportamiento de los residuos de cada uno de los modelos de manera gráfica. Para analizar la homocedasticidad de los residuos se graficaron los residuos versus las estimaciones realizadas con cada uno de los modelos, tal como se muestra en la Figura 4-5. En dicha figura se muestra que la media de los residuos de los modelos es cero y que, si bien no presentan un comportamiento estrictamente homocedástico, tampoco presentan un patrón sistemático claro, propio de una tendencia lineal o no lineal en la varianza de los residuos. El modelo de Julio-Caribe es el que presenta una varianza más heterogénea, ya que existen dos estimaciones que se alejan del comportamiento general de los residuos.

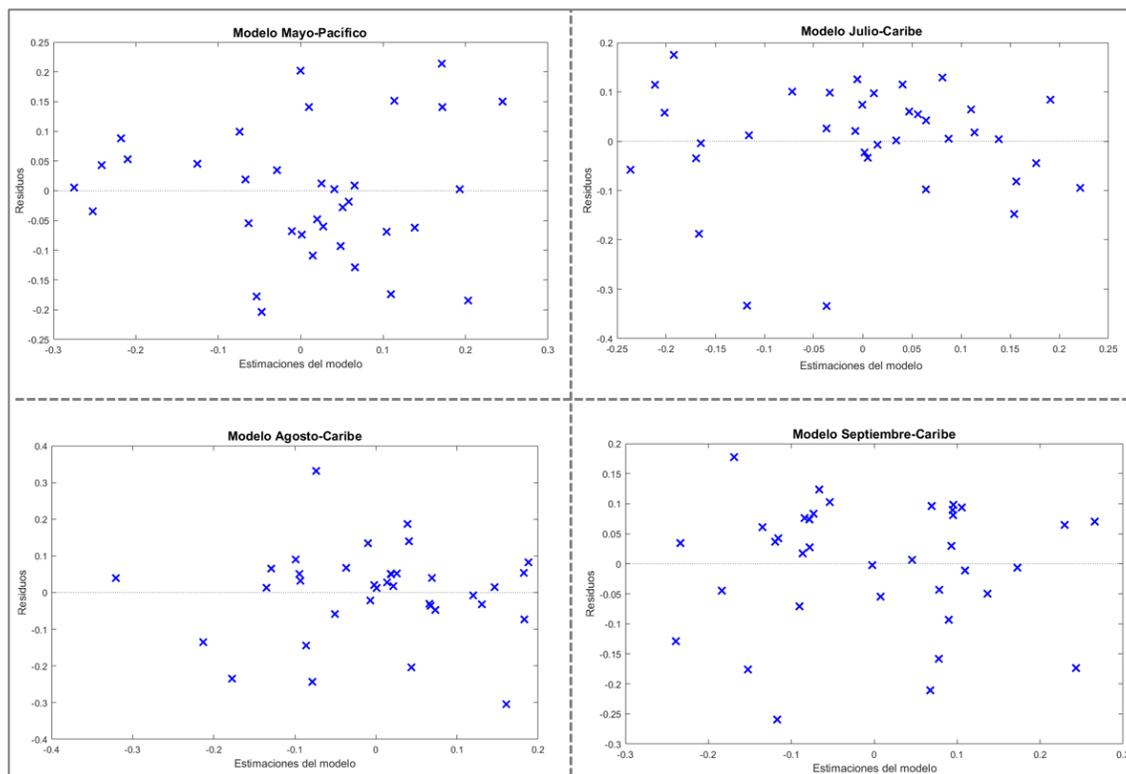


Figura 4-5: Comportamiento de los residuos versus las estimaciones para cada modelo de pronóstico

Para evaluar la independencia de los residuos, se graficaron los residuos versus los residuos desfasados, lo cual se puede ver en la Figura 4-6. En este caso la presencia de una tendencia lineal en el gráfico (positiva o negativa), es un indicador de la existencia de una correlación (positiva o negativa) en los residuos, por lo que bajo dicho escenario los residuos no son independientes. Para los gráficos de la Figura 4-6 no se observan tendencias lineales, sino un comportamiento uniforme alrededor del origen de los gráficos, por lo que se puede establecer que los residuos de los cuatro modelos de regresión son independientes.

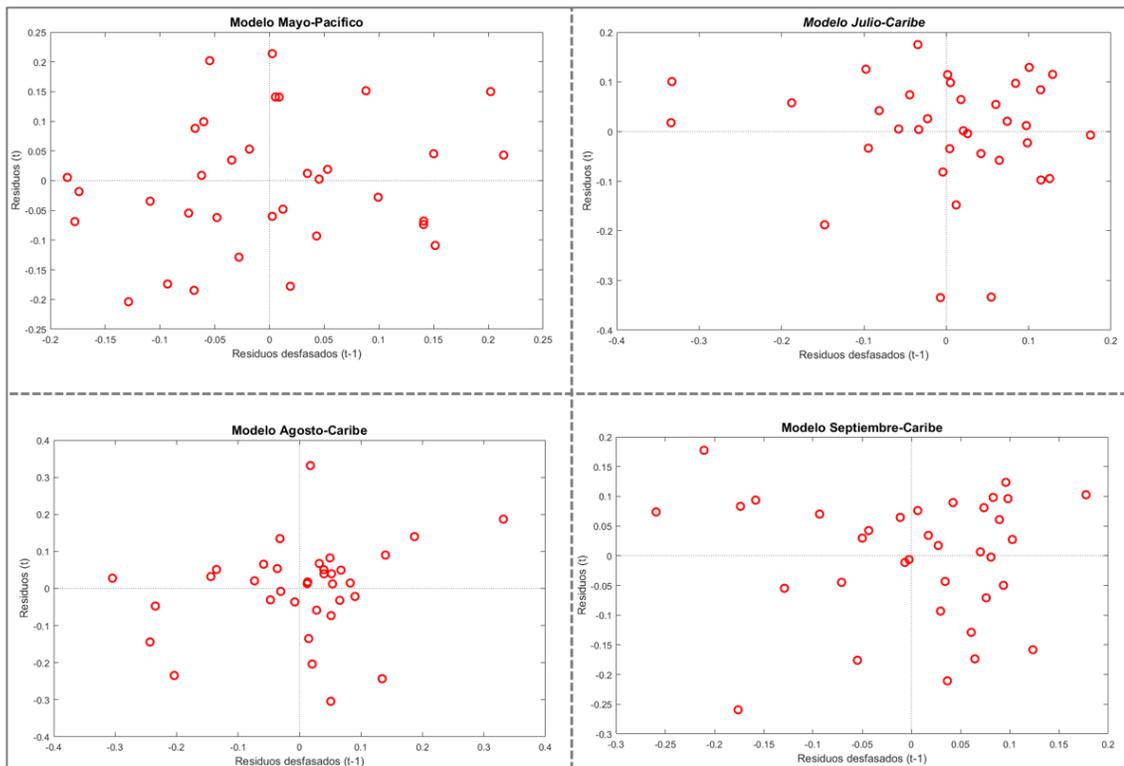


Figura 4-6: Evaluación de correlación en los residuos

En términos generales se puede establecer que los 4 modelos de regresión analizados cumplen con los supuestos del ajuste por el método de mínimos cuadrados ordinarios, de manera que se puede partir del supuesto que sus estimadores representan los mejores estimadores lineales insesgados. Adicionalmente, se demostró la significancia estadística de cada uno de los modelos, por lo que es posible establecer que éstos son apropiados para realizar predicciones, en este caso, los pronósticos del modo pacífico para el mes de mayo y el modo caribe para los meses de julio, agosto y septiembre, para posteriormente disponer de la precipitación en cada una de las estaciones consideradas.

4.3 Precipitación del mes de mayo en la vertiente pacífica

El modelo de regresión para el pronóstico del modo pacífico en el mes de mayo (Mayo-Pacífico) está dado por la ecuación (4.1). Los subíndices en las variables predictoras indican el desfase en meses de éstas con respecto a la variable de respuesta.

$$Mayo_{pacf} = 0,391 * SST9_{(7)} + 0,598 * SST27_{(7)} - 0,302 * SLP3_{(7)} + 0,226 * SST19_{(7)} \quad (4.1)$$

Dado que, para la construcción de los modelos, tanto los predictores como la variable de respuesta fueron centrados y normalizados, los coeficientes de los modelos son comparables entre ellos, por lo que se pueden utilizar para cuantificar el efecto de cada predictor sobre la variable de respuesta. Para el caso del modelo definido en (4.1), se puede ver que el EOF 27 del campo de SST es el que tiene la mayor influencia sobre la variable de respuesta. Sin embargo, para tomar en cuenta el efecto de los diferentes predictores, y poder analizar el patrón térmico y de presión que precede la variable de respuesta, en este caso con una antelación de 6 meses, se combinaron los EOF de cada uno de los predictores del modelo tomando en consideración el efecto de estos según el correspondiente coeficiente. En la Figura 4-7 se muestra el EOF combinado de SST tomando en consideración su efecto en la variable de respuesta y en la Figura 4-8 se observa el EOF de SLP3, el cual contempla el signo negativo que tiene dicha variable dentro del modelo.

En relación al patrón térmico, se observa que las anomalías más importantes para pronosticar la precipitación de mayo, se presentan en el sector oriental del pacífico ecuatorial, cercano a las costas de Ecuador y Perú. En cuanto a los patrones de presión, éstos se concentran en los sectores del Atlántico Norte y el Pacífico Norte. Sin embargo, es posible que el efecto principal sobre el modo pacífico en el mes de mayo sea producto del patrón que se presenta sobre el océano Atlántico, ya que éste tendría un efecto directo en la intensidad de los vientos alisios que llegan a Costa Rica y al resto de América Central. Esto ocurriría producto de la actividad de la Alta Subtropical del Atlántico Norte (responsable de la intensificación de los alisios), la cual su vez se ve influenciada por la

Oscilación del Atlántico Norte (NAO, por sus siglas en inglés) (Maldonado et al., 2018). Esta oscilación corresponde a un gradiente meridional de SLP que se da en el sector norte del océano Atlántico, similar al que aparece en la Figura 4-8.

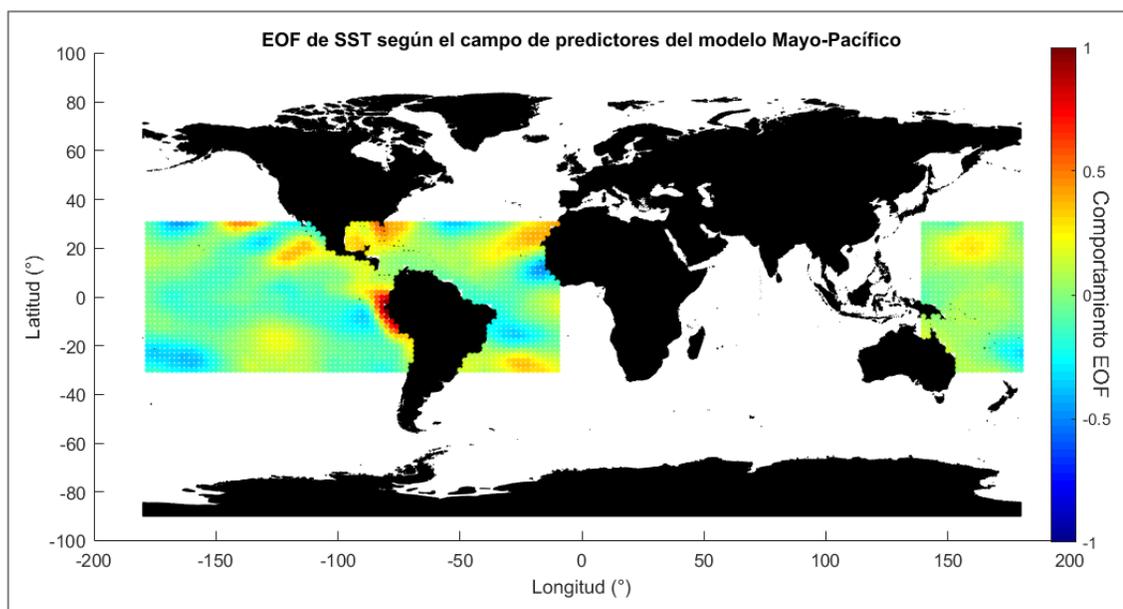


Figura 4-7: EOF combinado a partir de los EOF de SST contemplados en el modelo Mayo-Pacífico

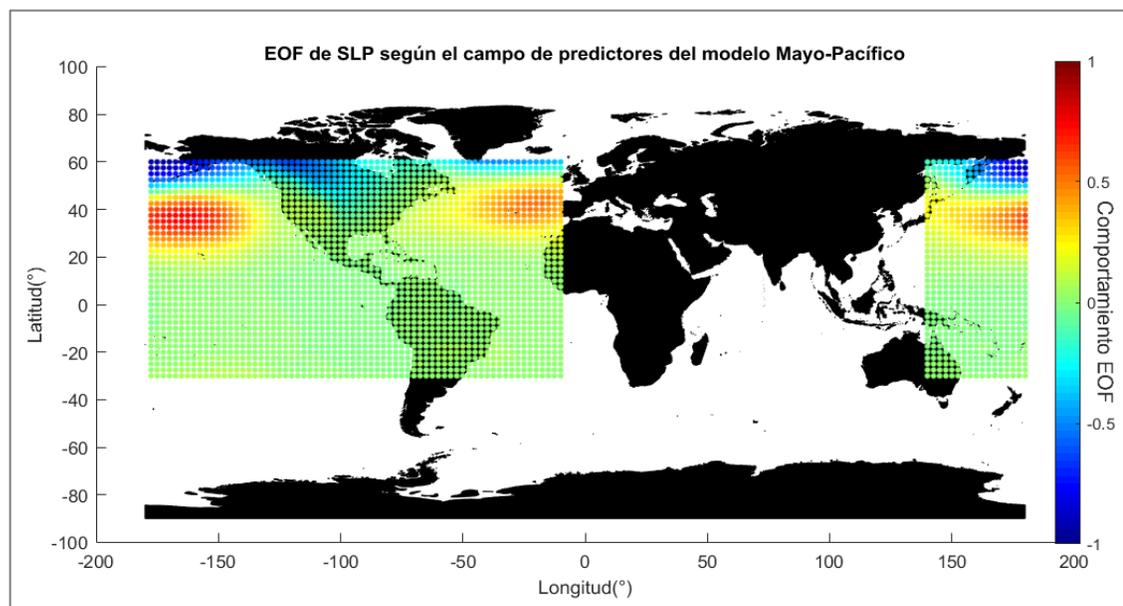


Figura 4-8: EOF de SLP contemplado en el modelo Mayo-Pacífico

Con base en los patrones de la Figura 4-7 y Figura 4-8, se puede establecer que anomalías positivas (negativas) de SST en las costas de Perú y Ecuador, acompañado con anomalías positivas (negativas) de SLP cercano a los 40° latitud norte en los océanos Atlántico y Pacífico, tienden a anteceder anomalías positivas (negativas) de precipitación durante el mes de mayo en la vertiente pacífica de Costa Rica. El efecto en las anomalías de precipitación se determinó considerando el comportamiento del modo pacífico (EOF 2 del campo de precipitación), según lo que se visualiza en la Figura 3-1.

Este enfoque del análisis realizado en el presente trabajo difiere de estudios anteriores, ya que en ellos se consideró el bimestre mayo – junio (MJ) como el período de análisis, correspondiente al primer máximo de precipitación de la vertiente pacífica de América Central (Alfaro et al., 2017; Maldonado et al., 2017). Para estos casos se determinó que la mayor predictibilidad de la precipitación total del bimestre MJ se obtenía con una antelación de 2 meses, la cual se basa principalmente en los patrones de SST del mes de febrero, específicamente en los sectores del Atlántico Norte Tropical (TNA, por sus siglas en inglés) y del pacífico tropical oriental. Para el presente trabajo, al considerar de manera separada los meses de mayo y junio, se determinó que es posible realizar pronósticos hábiles de la precipitación del primer mes con una antelación mucho mayor (6 meses). Esto se considera una mejoría en términos de pronóstico, ya que el mes de mayo representa el primer mes de lluvia posterior a la época seca, por lo que conocer el comportamiento de su precipitación mensual con anticipación permitiría tomar las medidas de mitigación necesarias, en especial cuando el pronóstico indique condiciones más secas de lo normal, que puedan afectar sectores como la agricultura y la producción hidroeléctrica.

4.3.1 Pronóstico de la precipitación de mayo en el pacífico

El pronóstico de la precipitación de mayo se realizó sobre las estaciones marcadas con triángulos en la Figura 4-1, las cuales representan 16 de la totalidad de las estaciones disponibles en el período de pronóstico (2016 – 2019). En la Tabla 4-9 se muestra el correspondiente valor del índice de precipitación estandarizado (SPI, por sus siglas en

inglés), tanto para los valores observados (medidos) como para los valores pronosticados (estimados) y el correspondiente valor de RSR medio para cada estación. En la Tabla 4-9 se destacan los casos en los que coincide la categoría del valor observado con la categoría del valor pronosticado.

Según los resultados de la Tabla 4-9 se puede ver que el año con mayor cantidad de aciertos es el 2016, con 12 aciertos, mientras que para los años 2017, 2018 y 2019 son 6, 7 y 8, respectivamente. Este comportamiento se debe a que las precipitaciones del mes de mayo de 2016 presentaron principalmente condiciones normales ($-1 < \text{SPI} < 1$), las cuales son más fácilmente pronosticadas por el modelo. Adicional a esto, es importante señalar que, si bien las condiciones de precipitación predominantes fueron clasificadas como normales, se puede ver que el modelo sí reprodujo adecuadamente la tendencia hacia las anomalías negativas registradas (no mostradas) en la mayoría de las estaciones, lo cual queda reflejado con los valores negativos de SPI.

Para los meses de mayo de los restantes años se presentan condiciones de precipitación más anómalas a lo largo de la vertiente pacífica de Costa Rica, para las cuales el modelo se ve limitado en su capacidad de pronóstico. Por ejemplo, para mayo de 2017 se registraron importantes anomalías positivas de precipitación en el norte del Pacífico Norte, noreste del Pacífico Central y el este del Valle Central (IMN, 2017), lo cual queda reflejado en los valores de SPI (>1) en más de la mitad de las estaciones. Para este caso la capacidad de pronóstico del modelo se ve limitada, ya que no es capaz de pronosticar estas condiciones húmedas. No obstante, el modelo sí tiene la capacidad de pronosticar, aunque sea de una manera más leve, la tendencia húmeda de mayo de 2017, ya que, para la mayoría de las estaciones, el SPI del valor pronosticado fue positivo y cercano a 1,0.

Tabla 4-9: Pronóstico categórico con los valores de SPI para mayo en la vertiente pacífica

Estación	2016		2017		2018		2019		RSR medio
	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	
100651	2,03	-0,45	2,69	0,62	-0,12	0,83	1,34	0,47	2,22
72165	1,11	-0,64	0,71	0,85	0,07	1,09	0,83	0,67	1,12
72163	-0,06	-0,80	0,63	0,97	0,93	1,19	0,82	0,79	0,38
72111	0,38	-0,46	0,37	0,77	0,12	0,97	1,69	0,62	1,05
73035	-0,28	-0,61	2,31	0,80	0,45	1,04	0,64	0,62	1,25
74008	-0,11	-0,42	-1,13	0,75	0,87	0,94	1,51	0,61	1,09
74020	-0,26	-0,89	1,47	0,98	-	-	-	-	0,61
80013	-0,17	-0,38	0,38	0,69	-0,40	0,87	0,23	0,55	0,74
82001	0,04	-0,53	0,33	0,73	-0,45	0,96	0,21	0,57	0,89
84141	0,24	-0,71	2,89	0,85	0,57	1,12	1,79	0,65	1,85
84019	-0,44	-0,67	2,54	0,85	0,76	1,10	1,18	0,65	1,44
84169	-1,68	-0,59	0,74	0,76	-0,41	1,00	0,29	0,58	0,90
84059	0,00	-0,83	1,49	0,92	1,23	1,23	-	-	0,61
90009	-0,37	-0,76	1,21	0,89	0,73	1,17	-0,12	0,68	0,56
96002	0,51	-0,71	1,38	0,86	-0,73	1,13	0,61	0,65	1,18
98097	-4,29	-0,87	5,12	0,94	3,71	1,28	2,06	0,70	4,01

Obs.: Observado

Est.: Estimado

Se señala en negrita los casos en los que coinciden las categorías estimadas con las observadas

En relación a la cantidad de aciertos de los pronósticos por categoría mencionados anteriormente, se obtuvo, a partir del uso de la distribución binomial, la probabilidad de obtener la misma cantidad de aciertos de manera aleatoria, tomando en cuenta la probabilidad de acierto (1/3) y la de fallo (2/3). Las probabilidades obtenidas fueron 0,1%, 19,0%, 11,5% y 4,0%, para el caso de los años 2016, 2017, 2018 y 2019, respectivamente. Con base en esto se puede ver que mayo de 2017 es el que presenta la probabilidad más alta de ser pronosticado de manera aleatoria. Sin embargo, aún bajo dicha probabilidad, el modelo aleatorio no supera al modelo de regresión construido, ya que este tipo de pronóstico aleatorio categórico, al no contemplar la distribución espacial de las anomalías de precipitación, no permite realizar inferencias respecto al comportamiento general esperado.

Para evaluar espacialmente la habilidad de pronóstico del modelo Mayo-Pacífico, se construyó el mapa de la Figura 4-9 a partir de los valores de RSR detallados en la Tabla

4-9. En dicha figura se puede observar que el modelo tiende a realizar mejores pronósticos en el sector occidental de la región del Valle Central y en las regiones de Pacífico Central y Pacífico Norte, siendo esta última una de las zonas que usualmente son más afectadas por los eventos de sequía (Fernández y Ramírez, 1991). Para las regiones donde se presenta una mejor habilidad de pronóstico, el RMSE estimado entre los valores medidos y los pronosticados es en promedio 105 mm, el cual no representa un valor tan alto, si se toma en cuenta que la precipitación promedio de mayo en dichas zonas ronda los 300 mm.

La segmentación espacial mencionada se llevó a cabo considerando las estaciones que presentaban valores de RSR cercanos o menores a 1,0. Por el contrario, en el sector oriental del Valle Central y en la región Pacífico Sur, la habilidad de pronóstico del modelo es limitada, lo cual se ve reflejado en el pronóstico por categorías y en los valores de RSR. En el caso de la región Pacífico Sur, la baja habilidad de pronóstico se debe a que esta región es explicada principalmente por el tercer EOF de precipitación (Anexo A2), el cual no fue incluido para la construcción de los modelos de regresión. Por lo tanto, para dicha región se podría incluir dentro del análisis, adicional al modo pacífico, el tercer EOF del campo de precipitación, para evaluar si con esa inclusión, se pueden mejorar los pronósticos en la región del Pacífico Sur de Costa Rica.

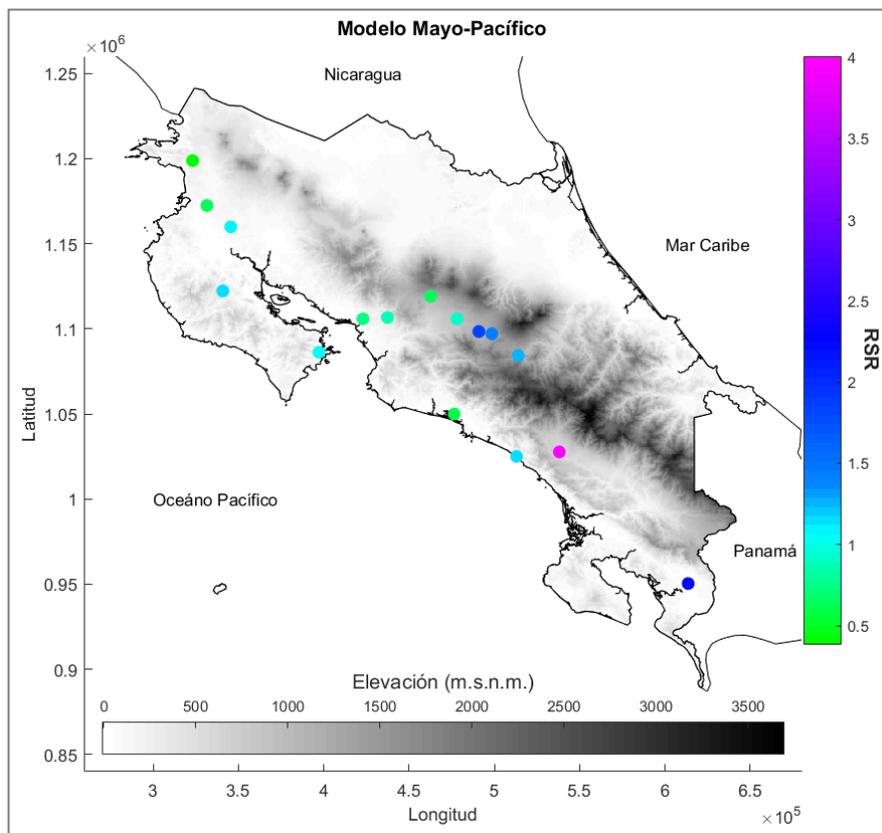


Figura 4-9: Distribución espacial del RSR según el pronóstico de la precipitación de mayo en el pacífico

4.4 Precipitación de los meses de julio, agosto y septiembre en la vertiente caribe

Para el modo caribe se consideraron los modelos de regresión construidos para los meses de julio, agosto y septiembre. De igual manera que con el modelo Mayo-Pacífico, se realizó una combinación de los EOF que componen el campo de predictores de los respectivos modelos, con el objetivo de analizar el efecto que tienen sobre la variable de respuesta.

4.4.1 Modelo Julio-Caribe

La ecuación del modelo de regresión para la estimación del modo caribe en el mes de julio está dada por la ecuación (4.2). Este modelo contempla un desfase de dos meses del campo de predictores con respecto a la variable de respuesta.

$$Julio_{Carib} = 0,310 * SST5_{(2)} + 0,530 * SST1_{(2)} - 0,257 * SST16_{(2)} + 0,378 * SST7_{(2)} \quad (4.2)$$

Para este caso se puede observar que el predictor que tiene la influencia más significativa sobre la variable de respuesta es SST1, asociado al fenómeno ENOS. Esto se ve reflejado en la Figura 4-10, en donde el patrón térmico combinado de los predictores se concentra a lo largo del pacífico ecuatorial oriental y las costas peruanas. Adicionalmente, el patrón combinado muestra una especie de gradiente o dipolo entre el SST del pacífico tropical oriental y el de la zona de TNA. Esta configuración de dipolo de SST entre ambos océanos ha sido ampliamente analizada y se ha relacionado con la intensidad de la precipitación en América Central y el Caribe, siendo ésta mayor cuando se presenta signos opuestos en la SST entre ambas regiones oceánicas (Enfield y Alfaro, 1999, Alfaro, 2002). En especial se ha estudiado la relación que existe entre dicho dipolo y la precipitación el segundo máximo de lluvia (agosto-septiembre-octubre) del modo bimodal de precipitación (similar al modo pacífico de Costa Rica) en América Central y el Caribe (Alfaro, 2007; Fallas y Alfaro, 2012; Maldonado et al, 2013), el cual, a nivel centroamericano, corresponde al modo de precipitación predominante.

Para el caso del modo caribe de Costa Rica durante el mes de julio, la configuración de dipolo de SST mencionada pareciera ser también el impulsor de la precipitación durante dicho mes. En este caso anomalías positivas (negativas) en el pacífico tropical oriental en conjunto con anomalías negativas (positivas) en el sector del Atlántico Norte Tropical producen anomalías positivas (negativas) de precipitación en la vertiente caribe de Costa Rica en el mes de julio. El efecto en las anomalías de precipitación se determinó

considerando el comportamiento del modo caribe (EOF 1 del campo de precipitación), según lo que se visualiza en la Figura 3-1.

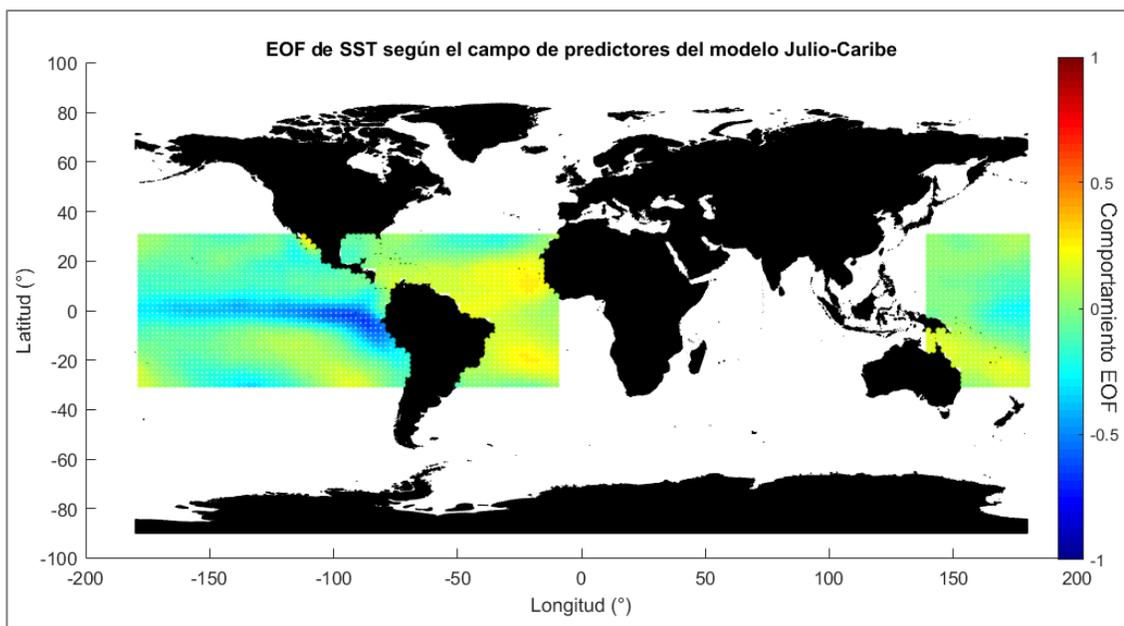


Figura 4-10: EOF combinado a partir de los EOF de SST contemplados en el modelo Julio-Caribe

4.4.2 Modelo Agosto-Caribe

El modelo de regresión para el mes de agosto es similar al del mes de julio, ya que ambos dependen solamente de predictores de SST. Además, ambos modelos de regresión comparten dos de los predictores, SST7 y SST1, teniendo este último una menor influencia para el modo caribe en el mes de agosto, en comparación con el mes de julio. El modelo de regresión para el mes de agosto queda definido según la ecuación (4.3).

$$Agosto_{Carib} = 0,474 * SST7_{(4)} + 0,367 * SST22_{(4)} + 0,351 * SST1_{(4)} \quad (4.3)$$

Realizando una combinación de los diferentes predictores del modelo definido en (4.3), se obtuvo el patrón espacial que se muestra en la Figura 4-11. Dicha figura presenta similitudes con el patrón de la Figura 4-10, sin embargo, en este caso no se presenta el dipolo de SST entre el pacífico tropical oriental y la región del atlántico norte tropical. Aun así, el efecto que tienen las anomalías de SST en las anomalías de precipitación de agosto es el mismo descrito para el mes de julio. Esto implica que se podrían considerar los meses de julio y agosto de manera agregada, con el objetivo de evaluar con un mayor nivel de detalle los mecanismos físicos más relevantes que anteceden la precipitación de este bimestre. Considerando los desfases de los predictores de los modelos individuales, la precipitación de julio y agosto están en función de las anomalías térmicas de mayo y abril, respectivamente. Por lo tanto, es posible que la precipitación del bimestre julio – agosto en la vertiente caribe de Costa Rica se pueda explicar solamente a partir de las anomalías de SST de los meses de mayo y abril, ya sea agregando o promediando dichas anomalías térmicas. Adicionalmente, tomando en cuenta lo que se observa en la Figura 4-10 y en la Figura 4-11, se considera que existe una clara influencia de ENOS en la precipitación de los meses de julio y agosto en el caribe, lo cual es congruente con el análisis de correlación mostrado en la Figura 3-10. En términos de pronóstico, el efecto de ENOS en el caribe tiene una mayor utilidad que en el pacífico, ya que su efecto se presenta para desfases mayores, al menos de 2 meses, mientras que en el pacífico es de solamente 1 mes, para el caso de agosto y septiembre.

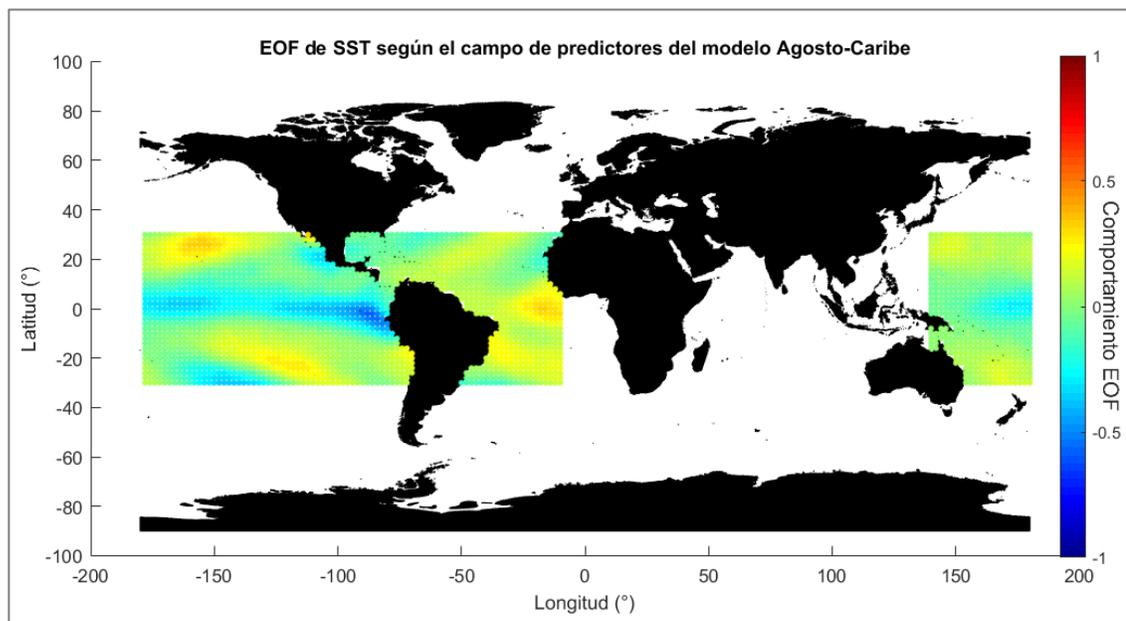


Figura 4-11: EOF combinado a partir de los EOF de SST contemplados en el modelo Agosto-Caribe

4.4.3 Modelo Septiembre-Caribe

El modelo de regresión para el modo caribe en el mes de septiembre, a diferencia de los modelos de julio y agosto anteriores, posee como variables predictoras la SST y la SLP. Para el mes de septiembre, la variable que tiene un mayor efecto en la variable de respuesta es SST2, tal como se observa en la ecuación (4.4).

$$Septiembre_{Carib} = -0,571 * SST2_{(5)} + 0,439 * SLP7_{(5)} - 0,340 * SST27_{(5)} \quad (4.4)$$

En la Figura 4-12 se observa el EOF resultante de la combinación de los predictores de SST del modelo definido en (4.4). En dicha figura se puede ver que el principal patrón responde a un contraste de las anomalías de SST entre el pacífico tropical oriental y un sector ubicado aproximadamente a los 20° de latitud norte, cercano a las costas de la península de Baja California, en México. Esto deja en evidencia que la precipitación del

mes de septiembre en la vertiente del caribe está afectada, en mayor medida, por la variabilidad térmica del océano pacífico oriental y no de la del océano Atlántico.

El patrón de la Figura 4-12 difiere a los mostrados para los meses de julio y agosto, por lo que se considera que la precipitación de septiembre debe ser tratada de manera separada a la de los otros meses. Dentro de la variación estacional de la precipitación del modo caribe y considerando específicamente el segundo semestre del año (en el cual se concentró el presente trabajo), los meses de septiembre y octubre representan meses de bajas precipitaciones, los cuales se encuentran en medio de dos períodos de altas precipitaciones; julio-agosto y noviembre-diciembre, similar a lo que ocurre con el mes de julio en la vertiente pacífica. Por lo tanto, es probable que los mecanismos físicos que controlan la precipitación de septiembre sean propios de dicho mes.

En relación al patrón de SLP, se puede ver en la Figura 4-13 que la mayor variabilidad se concentra en el sector norte del océano Atlántico, en donde se presenta una especie de dipolo zonal, entre las costas de América del Norte y Europa. Esta misma configuración de dipolo se presenta en el sector norte del océano Pacífico, sin embargo, tomando en cuenta la influencia de la Alta Subtropical del Atlántico Norte en el clima de América Central, es probable que las anomalías de precipitación del mes de septiembre en la vertiente caribe estén influenciadas por las anomalías de presión que se observan en el sector del Atlántico Norte.

Para el mes de septiembre se puede establecer que el gradiente de anomalías positivas (negativas) en el pacífico tropical oriental con anomalías negativas (positivas) en las cercanías de la península de Baja California, en conjunto con anomalías negativas (positivas) de presión en el Atlántico Norte (según su configuración de dipolo zonal) generan anomalías negativas (positivas) de precipitación en el mes de septiembre a lo largo de la vertiente caribe de Costa Rica.

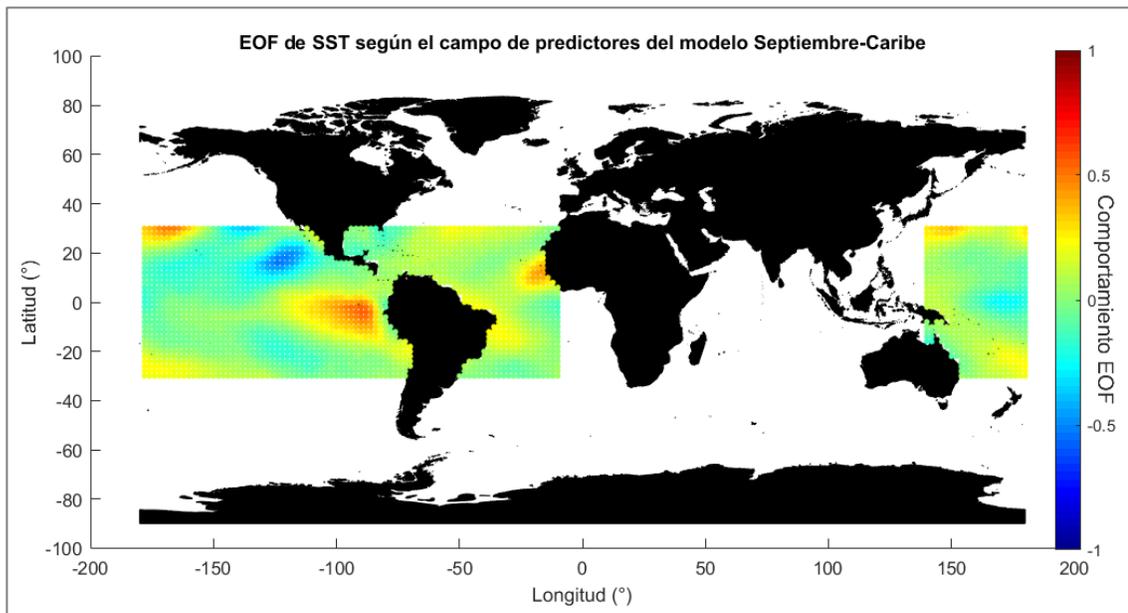


Figura 4-12: EOF combinado a partir de los EOF de SST contemplados en el modelo Septiembre-Caribe

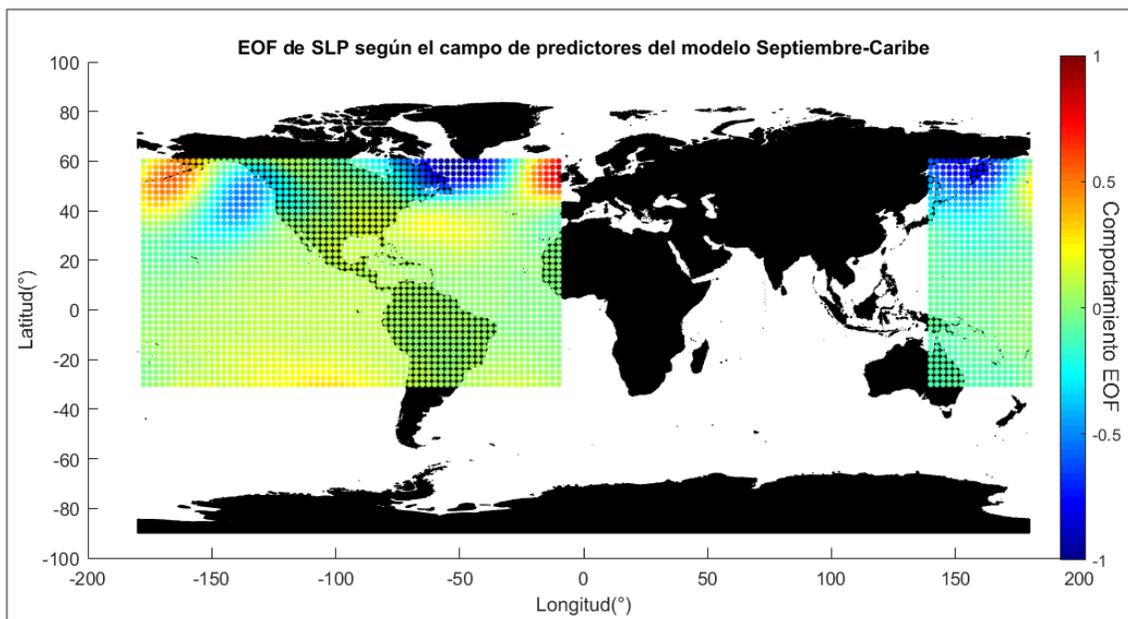


Figura 4-13: EOF de SLP contemplado en el modelo Septiembre-Caribe

4.4.4 Pronóstico de la precipitación de julio-agosto-septiembre en la vertiente caribe

El pronóstico de la precipitación en la vertiente caribe se realizó sobre las estaciones marcadas con cruces en la Figura 4-1, las cuales representan un tercio de la totalidad de las estaciones disponibles en el período de pronóstico 2016 – 2019. Al igual que para el caso del modelo Mayo-Pacífico, se construyó para cada mes una tabla que muestra los pronósticos por categorías según los valores del SPI y una figura con el mapeo del RSR medio de cada estación. Esto último con el objetivo de evaluar espacialmente la habilidad de pronóstico de cada uno de los modelos.

En la Tabla 4-10 se muestra el pronóstico categórico para el caso del mes de julio. Para los años 2016 y 2019 el pronóstico del modelo acertó en todas las estaciones, no obstante, es necesario señalar que ambos años presentaron condiciones de precipitación calificadas como normales, lo cual favoreció el desempeño del modelo. Por el contrario, el año 2018 correspondió al caso con la menor cantidad de aciertos, reportando solamente dos aciertos. Sin embargo, detallando los valores de SPI de las estimaciones, se puede ver que el modelo logró pronosticar, aunque de manera tenue, la tendencia húmeda del mes de julio de 2018, ya que para la mayoría de las estaciones se estimaron valores de SPI cercanos a 1. Aun así, es claro que el modelo, si bien logra pronosticar la tendencia, sus estimaciones se quedan cortas respecto a la magnitud de las condiciones de precipitación observadas, tal como quedó evidenciado en julio de 2018, el cual representó un mes particularmente húmedo, con superávits entre 100% y 160% en las anomalías de precipitación sobre la vertiente caribe de Costa Rica (IMN, 2018), condición que no pudo ser representada por el modelo.

La distribución espacial de la habilidad de pronóstico, cuantificada por medio de la métrica RSR, se puede apreciar en la Figura 4-14. Dicha figura muestra que la región de mayor predictibilidad es la Región Caribe, específicamente en las zonas más planas, cercanas a la costa, con valores de RSR cercanos o menores a 1,0. Esto contrasta con lo que se observa en las partes altas de la Región Caribe y en la Región Norte, donde la

habilidad del modelo es más limitada. En esta última región sobresale la estación 69515 Quebrada Azul, la cual presenta el valor más bajo de RSR, lo cual puede estar asociado a las condiciones promedio registradas en dicha estación durante el período de pronóstico.

Tabla 4-10: Pronóstico categórico con los valores de SPI para julio en la vertiente caribe

Estación	2016		2017		2018		2019		RSR medio
	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	
69515	-0,47	0,11	0,99	0,32	0,66	0,66	0,11	0,54	0,54
69537	0,21	0,15	-1,21	0,39	2,93	0,76	0,31	0,63	1,65
69556	-0,23	0,11	1,96	0,51	2,31	1,13	-0,70	0,91	1,45
69713	0,53	0,09	0,24	0,25	2,42	0,52	0,23	0,42	1,25
73155	-0,44	0,16	-0,64	0,48	3,06	0,97	-	-	2,01
73159	0,18	0,19	-0,21	0,50	2,24	0,97	0,14	0,81	1,00
81003	0,01	0,23	0,03	0,46	1,86	0,81	0,46	0,69	0,87
85012	0,39	0,21	-1,07	0,49	1,31	0,91	-0,24	0,76	0,94

Obs.: Observado

Est.: Estimado

Se señala en negrita los casos en los que coinciden las categorías estimadas con las observadas

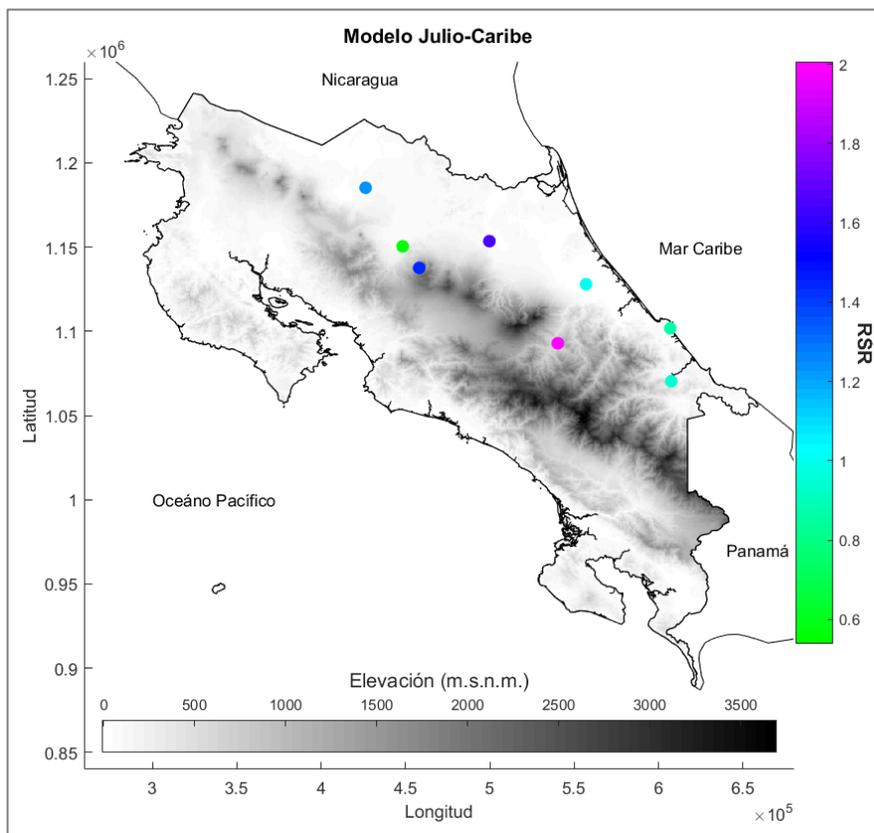


Figura 4-14: Distribución espacial del RSR según el pronóstico de la precipitación de julio en el caribe

Para el caso de agosto, el modelo de regresión presentó un buen desempeño, obteniendo para los 4 años de pronósticos una alta tasa de aciertos de las categorías basadas en el SPI (Tabla 4-11). Más aún, para la mayoría de los casos el modelo pronosticó la tendencia de las condiciones de precipitación observadas, en especial para los años 2016 y 2017.

Otro aspecto a rescatar del modelo de agosto son los valores bajos de RSR reportados, sinónimo de un buen pronóstico de los valores observados durante el período de pronóstico. Con base en dicha métrica, el modelo de agosto representa el modelo con la mayor habilidad predictiva entre los cuatro modelos analizados. En términos espaciales (Figura 4-15), el modelo de agosto presenta su menor habilidad de pronóstico en las zonas más planas de la vertiente caribe, es decir, las más alejadas del sistema montañoso que divide a Costa Rica. Aun así, el modelo de Agosto-Caribe presenta una buena habilidad

de pronóstico, ya que en promedio el RMSE obtenido con respecto a los valores medidos es 82,1 mm. Este valor de RMSE es aún menor (41,9 mm) si solamente se contemplan las 4 estaciones más cercanas a la cordillera. Tomando en cuenta que la precipitación media en la vertiente caribe durante el mes de agosto es 300 mm, se puede establecer que el modelo de Agosto-Caribe efectivamente tiene una buena habilidad de pronóstico.

Tabla 4-11: Pronóstico categórico con los valores de SPI para agosto en la vertiente caribe

Estación	2016		2017		2018		2019		RSR medio
	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	
69515	-0,58	-0,54	-0,85	-0,51	0,02	-0,01	-0,53	-0,12	0,24
69537	-0,59	-0,80	-1,37	-0,75	1,41	-0,01	0,12	-0,17	0,93
69556	-1,37	-1,01	-0,27	-0,95	-0,22	-0,09	-0,22	-0,28	0,35
69713	-0,16	-0,23	-0,64	-0,21	0,55	0,05	0,18	-0,01	0,36
73155	-1,08	-1,26	-0,09	-1,19	0,12	-0,10	-	-	0,57
73159	-0,74	-1,27	-0,26	-1,18	1,10	-0,03	0,86	-0,26	1,01
81003	-0,82	-1,26	-1,14	-1,16	0,95	0,00	0,67	-0,23	0,76
85012	-0,29	-0,96	-1,17	-0,90	-0,33	0,02	-0,50	-0,17	0,33

Obs.: Observado

Est.: Estimado

Se señala en negrita los casos en los que coinciden las categorías estimadas con las observadas

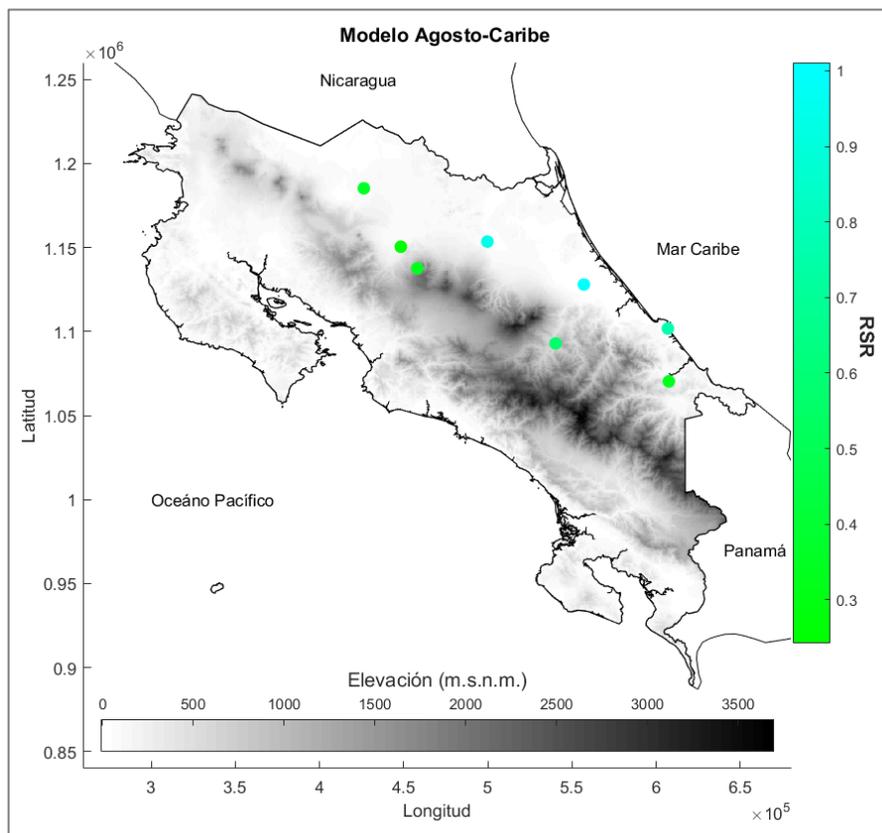


Figura 4-15: Distribución espacial del RSR según el pronóstico de la precipitación de agosto en el Caribe

Finalmente, se presentan los resultados de los pronósticos realizados con el modelo Septiembre-Caribe. En la Tabla 4-12 se muestran la cantidad de aciertos de los pronósticos según las categorías definidas y en la Figura 4-16 se observa la variación espacial de la habilidad de pronóstico. En general, se obtuvo prácticamente la misma cantidad de aciertos que para el caso del mes de agosto. Sin embargo, observando los valores de SPI se puede ver que se presenta una menor congruencia entre los valores observados y estimados que para el caso de agosto, ya que, aunque para muchos de los casos las condiciones de precipitación fueron normales, el signo del SPI fue diferente. Esto último implica que el signo de las anomalías de precipitación estimadas por el modelo no coincidió con el de las anomalías registradas, no obstante, dado que se mantienen bajo un escenario de precipitación normal, no se considera un pronóstico inadecuado.

En cuanto a la habilidad espacial de pronóstico, según la Figura 4-16, el modelo Septiembre-Caribe presenta un comportamiento similar al del modelo para el mes de julio y opuesto al del mes de agosto. La mayor habilidad de pronóstico se da en las estaciones ubicadas en las partes más planas de la vertiente caribe, las que se encuentran más alejadas del sistema montañoso. En general el error de pronóstico fue bajo, con un RMSE igual a 61,7 mm, el cual corresponde al menor valor entre los modelos considerados para la vertiente caribe, si se consideran todas las estaciones disponibles. Sin embargo, analizando los valores de SPI de las observaciones, se puede ver que, en los años de pronóstico disponibles, la precipitación del mes de septiembre presentó primordialmente condiciones normales, por lo que realmente el modelo de regresión no fue puesto a prueba para evaluar su habilidad predictiva para pronosticar escenarios de precipitación anómalos, ya se húmedos o secos. Por lo tanto, no es posible establecer, con la información disponible, si el modelo Septiembre-Caribe posee una utilidad operacional para la elaboración de los pronósticos de la precipitación del mes de septiembre, aunque es muy probable que el presente modelo de regresión sí represente una mejora con respecto a un modelo basado en la climatología.

Tabla 4-12: Pronóstico categórico con los valores de SPI para septiembre en la vertiente caribe

Estación	2016		2017		2018		2019		RSR medio
	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	
69515	-0,41	0,17	-0,72	-0,01	0,10	0,10	-0,09	-0,04	0,44
69537	0,28	0,25	-0,19	-0,08	-0,56	0,13	-0,34	-0,14	0,35
69556	-1,35	0,21	0,62	-0,09	-0,31	0,10	-0,15	-0,14	0,85
69713	-0,25	0,15	1,40	0,06	-0,52	0,12	-0,66	0,04	0,95
73155	-1,51	0,26	0,81	-0,17	0,08	0,10	-	-	1,11
73159	0,68	0,44	-1,08	-0,31	-	-	0,44	-0,45	0,66
81003	0,98	0,43	-1,41	-0,17	-0,24	0,22	0,50	-0,28	0,72
85012	-0,38	0,33	-1,64	-0,11	0,00	0,17	-0,47	-0,19	0,69

Obs.: Observado

Est.: Estimado

Se señala en negrita los casos en los que coinciden las categorías estimadas con las observadas

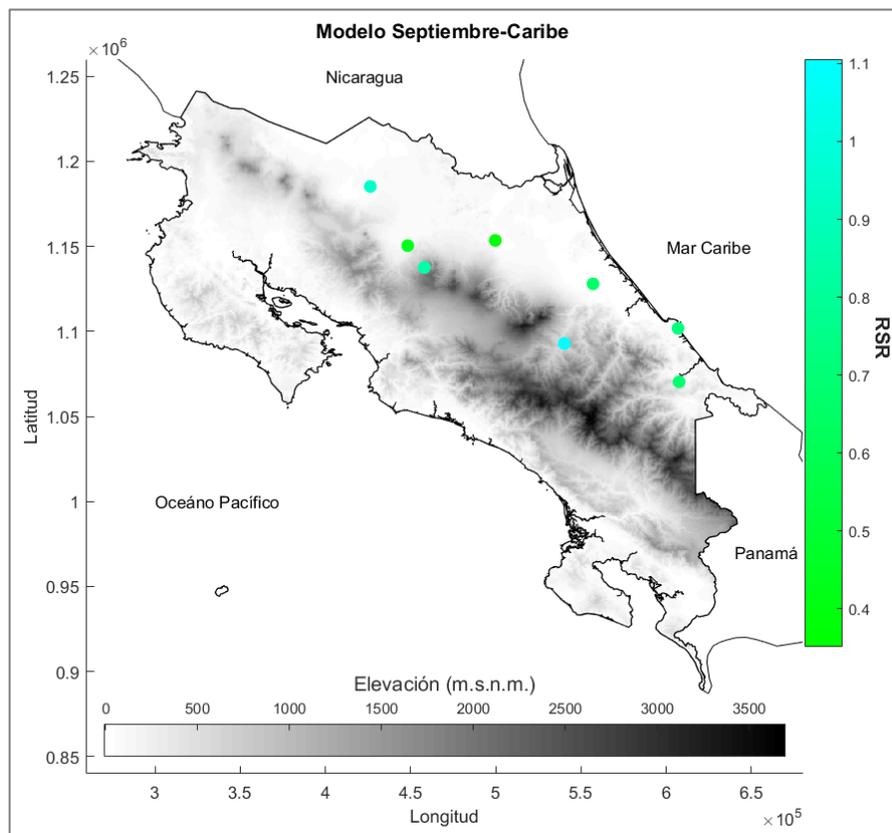


Figura 4-16: Distribución espacial del RSR según el pronóstico de la precipitación de septiembre en el caribe

En relación a la cantidad de aciertos de las categorías de pronóstico conseguidas por los modelos de regresión para el modo caribe, se estimó la probabilidad de obtener ese mismo número de aciertos de manera aleatoria. En la Tabla 4-13 se muestran la cantidad de aciertos de cada modelo y la probabilidad asociada, según la distribución binomial. En dicha tabla se puede ver que en general la mayoría de las probabilidades son bajas, por lo tanto, en términos de pronóstico por categorías, los tres modelos son superiores a un modelo basado exclusivamente en el azar. El pronóstico del modelo Julio-Caribe durante el 2018 es el que tiene la probabilidad más alta de ser igualado por un pronóstico aleatorio, ya que solamente acertó 2 de los 8 posibles pronósticos. Sin embargo, julio de 2018 fue un mes particularmente húmedo, el cual, si bien el modelo no logró pronosticar la

categoría, sí logró pronosticar, aunque sea en menor medida, la tendencia húmeda del mes. Por lo tanto, en ese tipo de casos es importante valorar los resultados del pronóstico de manera más detallada y evitar evaluarlos solamente desde un punto de vista categórico, el cual, si bien tiene una utilidad operativa, puede ocultar información valiosa del pronóstico realizado.

Tabla 4-13: Probabilidad de obtención de forma aleatoria el número de aciertos de los modelos

<i>Año</i>	<i>Julio-Caribe</i>		<i>Agosto-Caribe</i>		<i>Septiembre-Caribe</i>	
	Aciertos	Probabilidad	Aciertos	Probabilidad	Aciertos	Probabilidad
<i>2016</i>	8	0,02%	6	1,71%	6	1,71%
<i>2017</i>	5	6,83%	4	17,1%	4	17,1%
<i>2018</i>	2	27,3%	6	1,71%	7	0,05%
<i>2019</i>	7	0,05%	7	0,05%	7	0,05%

5 CONCLUSIONES

En el presente trabajo se analizó el efecto que tienen los patrones de temperatura superficial del mar (SST) y de presión nivel del mar (SLP) de los océanos circundantes en la precipitación estacional de Costa Rica, por medio de la implementación de modelos de regresión lineal para cada uno de los meses de interés. A partir de estos modelos se evaluó la habilidad real de pronóstico que tienen los patrones térmicos y de presión, con el objetivo de determinar su utilidad como predictores de la precipitación estacional en Costa Rica. A continuación, se presentan las principales conclusiones del estudio realizado.

Por medio de un análisis de componentes principales del campo de la precipitación mensual en Costa Rica, se determinó que gran parte de la varianza en la precipitación se puede representar de manera adecuada a partir de los primeros dos componentes principales. El primer componente corresponde principalmente a variaciones en la precipitación en la vertiente caribe del país (Modo Caribe), mientras que el segundo abarca las variaciones en la vertiente pacífica y la región del Valle Central (Modo Pacífico), quedando el comportamiento espacial de cada modo de precipitación dividido por el sistema montañoso que atraviesa al país. Esto indica que las variaciones a cada lado del sistema montañoso no están correlacionadas, dejando en claro el efecto que tiene la topografía en la variabilidad de la precipitación en cada una de las vertientes de Costa Rica (Fernández et al., 1996), lo cual en parte es producto de la orientación perpendicular que tiene el sistema montañoso con los vientos alisios provenientes del noreste (Maldonado et al., 2018).

El modo caribe representa el modo de precipitación predominante en Costa Rica. Esto representa una diferencia importante con el resto de América Central y el Caribe, ya que para dichas regiones el modo de precipitación principal presenta el comportamiento bimodal característico del modo pacífico de Costa Rica, con máximos de precipitación en los meses de mayo – junio y septiembre – octubre y una disminución de las lluvias entre julio y agosto (Giannini et al., 2000; Alfaro, 2002; Alfaro, 2007). Para el modo caribe se determinó que los primeros 6 meses del año no parecieran poder ser explicados a partir de

los patrones de SST y SLP considerados, o al menos, los resultados obtenidos muestran que no existe una relación lineal entre dichos patrones y la precipitación en el primer semestre del año. Por lo tanto, es probable que la precipitación de los primeros 6 meses del año en la vertiente caribe de Costa Rica sea explicada por otras variables, posiblemente a una escala más local, o que sea necesario considerar relaciones no lineales.

El análisis del modo caribe se limitó al trimestre julio-agosto-septiembre (JAS), ya que para esos tres meses los modelos desarrollados, no solo presentaban una buena habilidad predictiva, sino que se desempeñaron mejor que los modelos de referencia de climatología y persistencia. Para el caso de los meses de julio y agosto, los modelos muestran que la precipitación de dichos meses es explicada solamente por patrones térmicos, específicamente los que se presentan en la región oriental del pacífico ecuatorial durante los meses de mayo y abril, según los desfases de los respectivos modelos. Es probable que dichos patrones estén relacionados a las fluctuaciones en la intensidad y ubicación de la zona de convergencia intertropical (ZCIT), las cuales se presentan usualmente durante el mes de mayo y que han sido asociadas a la disminución de la precipitación que se presenta en la vertiente pacífica de América Central, en los meses de julio y agosto, conocida en inglés como Midsummer Drought (MDS) (Magaña et al., 1999). Según estos autores, la transición de la actividad convectiva de intensa a débil (débil a intensa) genera que los vientos alisios sobre el Caribe se intensifiquen (debiliten). Dicha intensificación de los alisios durante julio y agosto, en conjunto con la interacción con el sistema montañoso de América Central, da como resultado un máximo de precipitación a lo largo de las costas caribeñas y un mínimo de precipitación a lo largo de la vertiente pacífica. Por su parte, la precipitación del mes de septiembre es explicada en gran medida, e independientemente del desfase considerado, por el segundo EOF del campo de SST, el cual se caracteriza por presentar un dipolo entre las anomalías térmicas del pacífico ecuatorial oriental y las anomalías térmicas en la zona cercana a la península de Baja California. Adicionalmente, el modo caribe en septiembre está en función también de la variabilidad de SLP en la región del Atlántico Norte. Esto demuestra que la precipitación del mes de septiembre es un caso particular, con una dinámica independiente

a lo que ocurre en los meses anteriores y para el cual se requiere eventualmente un análisis más detallado. Aun así, es importante notar que el modo caribe muestra una mayor relación con la variabilidad de SST en el océano Pacífico que en el océano Atlántico o en el mar Caribe.

Para el caso del modo pacífico, el cual corresponde al modo de precipitación predominante a escala centroamericana, se consideraron los meses que abarcan la época lluviosa, comprendida entre mayo y octubre. Para dicho período se obtuvieron resultados que en cierta medida contrastan con los reportados en investigaciones previas. Dado que en el presente estudio se consideró de manera diferenciada cada mes de la época lluviosa, se pudo determinar que la precipitación de los meses que han sido tradicionalmente agrupados, mayo-junio (MJ) y agosto – septiembre – octubre (ASO), no necesariamente es explicada por las mismas variables. Esta conclusión surge a raíz de la inclusión de la SLP como variable explicativa, ya que usualmente se consideraba principal solamente la SST como predictor.

Para el bimestre MJ se determinó que existe una clara diferencia en las variables que explican la precipitación en ambos meses, ya que mientras el modo pacífico en el mes de mayo está en función principalmente de patrones térmicos, en junio el modo pacífico presenta una mayor relación con los patrones de presión. Por lo tanto, pareciera ser factible el considerarlos de manera separada. Dicha separación trae consigo la ventaja de que para el mes de mayo se obtuvo un modelo de pronóstico hábil, con un desfase de sus predictores de 7 meses, lo cual en términos de pronóstico representa una mejora en comparación con los casos en los que se ha considerado de manera agregada el bimestre MJ (Maldonado et al., 2017; Alfaro et al., 2017). El modelo construido para mayo muestra que la precipitación de dicho mes está en función principalmente de las anomalías térmicas que se presentan en el pacífico ecuatorial oriental, en las zonas cercanas a las costas de Ecuador y Perú. Esto se puede asociar a una dependencia del comportamiento de ENOS, ya que la zona antes descrita corresponde en gran medida a la región Nino 1+2.

Para el trimestre ASO, los resultados indican que el modo pacífico para el caso de los meses de agosto y septiembre responde a las anomalías térmicas de SST que se desarrollan en el pacífico tropical ecuatorial, en los meses de julio y agosto, respectivamente, propias de la variabilidad generada por el fenómeno de ENOS. Estos resultados son congruentes con estudios previos en los que se ha establecido que la predictibilidad del trimestre ASO, pero en especial de los meses de agosto y septiembre, está en función de las anomalías de SST del mes de julio (Fallas y Alfaro, 2012; Maldonado et al., 2013) Sin embargo, los resultados muestran que la precipitación del mes de octubre pareciera responder principalmente a anomalías de presión, por lo que no es explicada de la misma manera en que lo hace precipitación del bimestre anterior. La diferencia entre los resultados obtenidos en este trabajo y lo establecido en estudios previos, se puede deber a que el efecto de las anomalías de SST en julio es dominante para los meses de agosto y septiembre, por lo que cuando se agrupa todo el período ASO, la fuente que explica la precipitación de dicho trimestre sigue siendo la SST de julio. Por lo tanto, se puede concluir que la manera en que se agrupan los meses de precipitación es relevante dentro del análisis de las variables que explican la precipitación, siendo el efecto más fuerte a nivel mensual el que tiende a sobresalir cuando se considera un período agregado de dos o tres meses (Uvo et al., 1998).

A partir de los análisis de los pronósticos de precipitación realizados con los modelos de julio, agosto y septiembre, para el modo caribe, y el modelo del mes de mayo, para el modo pacífico, se determinaron zonas caracterizadas por una mayor predictibilidad. Para el caso del modo pacífico en el mes de mayo, se observó que la precipitación en las regiones Pacífico Norte, Pacífico Central y el sector occidental de la región del Valle Central presenta un mayor potencial de ser pronosticada. En el caso particular de la región Pacífico Norte, estos resultados representan una ventaja, ya que usualmente esta región se ve afectada por la disminución de las precipitaciones, en especial al inicio de la época lluviosa, debido a que es el momento en el que se tiene la menor disponibilidad del recurso hídrico, principalmente para actividades como la agricultura. Para el trimestre JAS del modo caribe, se observó que la variación espacial de

la habilidad de pronóstico es influenciada por la topografía, ya que en general, las estaciones más alejadas de la cordillera, es decir las que se encuentran en las zonas más planas, son las que presentan mejores resultados en términos de pronóstico.

En términos generales se puede establecer que los modelos analizados en detalle - los que superaron en desempeño a los modelos de referencia - tienen una habilidad de pronóstico aceptable, en especial si el objetivo es determinar la tendencia de las condiciones de precipitación en las zonas de mayor predictibilidad. Esto último se puede concluir a partir de los pronósticos categóricos realizados con base en el índice de precipitación estandarizado (SPI). Adicionalmente, los desfases temporales del campo de predictores de los modelos los convierten en una herramienta de pronóstico relevante, ya que permiten pronosticar, con una importante antelación, las potenciales condiciones de precipitación. Para el caso del mes de mayo en el pacífico es posible hacer pronósticos con una habilidad significativamente mayor a la climatología, con una antelación de 6 meses, mientras que para el trimestre JAS de la vertiente caribe, las condiciones se pueden pronosticar a partir de las anomalías de SST y SLP de los meses de abril y mayo. No obstante, es importante mencionar que los modelos tienen una habilidad limitada para estimar condiciones extremas, ya sea condiciones muy húmedas o condiciones muy secas.

El presente trabajo permite establecer la relación que tienen las variables SST y SLP con la precipitación estacional de Costa Rica y la capacidad que tienen para explicarla y pronosticarla. Sin embargo, aún es necesario ahondar en los mecanismos físicos que subyacen dichas relaciones, lo que permitiría, no solo mejorar el entendimiento de los fenómenos, sino considerar otras variables predictivas que permitan aumentar, ya sea la capacidad o la ventana de pronóstico. Tomando en cuenta el efecto tan relevante que tienen las anomalías térmicas del pacífico ecuatorial oriental en la precipitación de varios meses en Costa Rica, se considera que podría ser relevante la inclusión, dentro de las variables explicativas, de la termoclina del pacífico, la cual, al tener una mayor inercia que la SST, podría llegar a ampliar la antelación de los pronósticos.

BIBLIOGRAFIA

- Adnan, M., Rehman, N., Ali, S., Mehmood, S., Anwar Mir, K., Ahmad Khan, A. & Khalid B. (2017). Prediction of summer rainfall in Pakistan from global sea-surface temperature and sea-level pressure. *Weather*, 72, 76 – 84.
- Alfaro, E. J. (2002). Some characteristics of the annual precipitation cycle in Central America and their relationships with its surrounding tropical oceans. *Tópicos Meteorológicos y Oceanográficos*, 9, 88 – 103.
- Alfaro, E. J. (2007). Uso del análisis de correlación canónica para la predicción de la precipitación pluvial en Centroamérica. *Ingeniería y Competitividad*, 9, 33 – 48.
- Alfaro, E. J., Hidalgo, H. & Mora, N. (2016). Prediction of MJ rainfall season using CCA models. *Tópicos Meteorológicos y Oceanográficos*, 15, 5 – 19.
- Bennett, N., Croke, B., Guariso, G., Guillaume, J., Hamilton, S., Jakeman, A., Marsili-Libelli, S., Newham, L., Norton, J., Perrin, C., Pierce, S., Robson, B., Seppelt, R., Voinov, A., Fath, B., Andreassian, V. (2013). Characterising performance of environmental models. *Environmental Modelling & Software*, 40, 1 – 20.
- Boyin Huang, Peter W. Thorne, Viva F. Banzon, Tim Boyer, Gennady Chepurin, Jay H. Lawrimore, Matthew J. Menne, Thomas M. Smith, Russell S. Vose, & Huai-Min Zhang (2017). NOAA Extended Reconstructed Sea Surface Temperature (ERSST), Version 5. NOAA National Centers for Environmental Information. doi:10.7289/V5T72FNM.
- Cawley, G. & Talbot, N. (2010). On over-fitting in model selection and subsequent selection bias in performance evaluation. *Journal of Machine Learning Research*, 11, 2079 – 2107.
- Drosowsky W. & Chambers, L. (2001). Near-global sea surface temperature anomalies as predictors of australian seasonal rainfall. *Journal of Climate*, 14, 1677 – 1687.
- Enfield, D. B., & Alfaro, E. J. (1999). The dependence of caribbean rainfall on the interaction of the tropical Atlantic and Pacific oceans. *Journal of Climate*, 12, 2093 – 2103.
- Fallas-López, B., & Alfaro, E. J. (2012). Uso de herramientas estadísticas para la predicción estacional del campo de precipitación en América Central como apoyo a los Foros Climáticos Regionales. 1: Análisis de Tablas de Contingencia. *Revista de Climatología*, 12, 61 – 79.

Fallas-López, B., & Alfaro, E. J. (2012). Uso de herramientas estadísticas para la predicción estacional del campo de precipitación en América Central como apoyo a los Foros Climáticos Regionales. 2: Análisis de Correlación Canónica. *Revista de Climatología*, 12, 93 – 105.

Fernández, W. & Ramírez, P. (1991). El Niño, la Oscilación del Sur y sus efectos en Costa Rica: una revisión. *Tecnología en Marcha*, 1, 3 – 10.

Fernández, W., Chacón, R., & Melgarejo, J. W. (1996). On the rainfall distribution with altitude over Costa Rica. *Revista Geofísica*, 44, 57 – 72.

Folland, C., Owen, J., Ward, M. N., & Colman, A. (1991). Prediction of seasonal rainfall in the Sahel region using empirical and dynamic methods. *Journal of Forecasting*, 10, 21 – 56.

Giannini, A., Kushnir, Y., & Cane, M. A. (2000). Interannual variability of caribbean rainfall, ENSO, and the Atlantic ocean. *Journal of Climate*, 13, 297 – 311.

Giannini, A., Cane, M., Kushnir, Y. (2001). Interdecadal changes in the ENSO teleconnection to the caribbean region and the North Atlantic oscillation. *American Meteorological Society*, 14, 2867 – 2879.

Gouirand, I., Moron, V., Hu, Z. & Jha, B. (2014). Influence of the warm pool and cold tongue El Niños on the following caribbean rainy season rainfall. *Climate Dynamics*, 42, 919 – 929.

Hastie, T., Tibshirani, R. & Friedman, J. (2009). *The elements of statistical learning*. Segunda Edición. Springer.

Instituto Meteorológico Nacional. (1998). Caracterización pluviométrica de la fase cálida de ENOS en Costa Rica con base en probabilidades de ocurrencia de eventos en tres escenarios: seco, normal y lluvioso. Recuperado de <https://www.imn.ac.cr/documents/10179/20911/El+Ni%C3%B1o+y+probabilidades+de+lluvia+en+escenarios>

Instituto Meteorológico Nacional. (2017). Boletín Meteorológico Mensual: Mayo 2017.

Instituto Meteorológico Nacional. (2018). Boletín Meteorológico Mensual: Julio 2018.

James, G., Witten, D., Hastie, T. & Tibshirani, R. (2000). *An introduction to statistical learning*. Primera Edición. Springer Science+Business Media.

Jhonson, R. & Wichern, D. (2007). *Applied multivariate statistical analysis*. Sexta Edición. Pearson Education.

Lloyd-Hughes, B. & Saunders, M. (2002). Seasonal prediction of European spring precipitation from El Niño-Southern Oscillation and local sea-surface temperatures. *International Journal of Climatology*, 22, 1 – 14.

M. Kanamitsu, W. Ebisuzaki, J. Woollen, S-K Yang, J.J. Hnilo, M. Fiorino, & G. L. Potter. (2002). NCEP-DOE AMIP-II Reanalysis (R-2). *Bulletin of the American Meteorological Society*, 1631 – 1643.

Magaña, V., Amador, J. A., & Medina, S. (1999). The midsummer drought over Mexico and Central America. *Journal of Climate*, 12, 1577 – 1588.

Maldonado, T., Alfaro, E., Fallas-López, B., & Alvarado, L. (2013). Seasonal prediction of extreme precipitation events and frequency of rainy days over Costa Rica, Central America, using Canonical Correlation Analysis. *Advances in Geosciences*, 33, 41 – 52.

Maldonado, T., Alfaro, E., Rutgersson, A., & Amador, J. A. (2017). The early rainy season in Central America: the role of the tropical North Atlantic SSTs. *International Journal of Climatology*, 37, 3731 – 3742.

Maldonado, T., Alfaro, E., & Hidalgo, H. (2018). A Review of the main drivers and variability of Central America's Climate and seasonal forecast systems. *Revista Biología Tropical*, 66, S153 – S175

Manso P., Stolz, W. & Fallas, J. (2005). El régimen de la precipitación en Costa Rica. *Ambientico*, 144, 7 – 8.

Mckee, T., Doesken, N. & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceeding of the Ninth Conference on Applied Climatology*. American Meteorological Society: Boston; 179 – 184.

Moriasi, D., Arnold, J., Van Liew, M., Bingner, R., Harmel, R. & Veith, T. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *American Society of Agricultural and Biological Engineers*, 50, 885 – 900.

Mutai, C. C., Ward, M. N., & Colman, A. W. (1998). Towards the prediction of the East Africa short rains based on sea-surface temperature-atmosphere coupling. *International Journal of Climatology*, 18, 975 – 997.

Preisendorfer, R. (1988). *Principal component analysis in meteorology and oceanography*. C.D. Mobley, (Ed.). Primera Edición. Elsevier. Amsterdam.

Solano, J. & Villalobos, R. (2001). Aspectos fisiográficos aplicados a un bosquejo de regionalización geográfico climático de Costa Rica. *Tópicos Meteorológicos y Oceanográficos*, 8, 26 – 39.

Spence, J. M., Taylor, M. A., & Chen, A. A. (2004). The effect of concurrent sea-surface temperature anomalies in the tropical Pacific and Atlantic on Caribbean rainfall. *International Journal of Climatology*, 24, 1531 – 1541.

Sittichok, K., Djibo, A. G., Seidou, O., Saley, H. M., Karambiri, H., & Paturel, J. (2016). Statistical seasonal rainfall and streamflow forecasting for the Sirba watershed, West Africa, using sea-surface temperatures. *Hydrological Sciences Journal*, 61, 805 – 815.

Uvo, C. B., Repelli, C. A., Zebiak, S. E., & Kushnir, Y. (1998). The relationship between tropical Pacific and Atlantic SST and northeast Brazil monthly precipitation. *Journal of Climate*, 11, 551 – 562.

Valdés-Pineda, R. (2014). *Analysis of long-term changes in annual and seasonal precipitation in Chile and related large-scale atmospheric circulation patterns*. Tesis de maestría. Universidad de Arizona.

Walpole, R., Myers, R. Myers, S. & Ye, K. (2011). *Probability & statistics for engineers & scientistis*. Novena Edición. Prentice Hall.

Ward, M. N., & Folland, C. K. (1991). Prediction of seasonal rainfall in the north nordeste of Brazil using eigenvectors of sea-surface temperature. *International Journal of Climatology*, 11, 711 – 743.

Waylen, P. R., Caviedes, C. N., & Quesada, M. E. (1996). Interannual variability of monthly precipitation in Costa Rica. *Journal of Climate*, 9, 2606 – 2613.

Waylen, P. R. (1996). Temporal and spatial variability of annual precipitation in Costa Rica and the Southern Oscillation. *International Journal of Climatology*, 16, 173 – 193.

Wilks, D.S. (2006). *Statistical methods in the atmospheric sciences: An introduction*. Segunda Edición. Academic Press. San Diego.

World Meteorological Organization (2012). Standardized Precipitation Index User Guide.

Xu, Q., Liang, Y. & Du, Y. (2004). Monte Carlo cross-validation for selecting a model and estimating the prediction error in multivariate calibration. *Journal of Chemometrics*, 18, 112 – 120.

Xu, Y. & Goodacre, R. (2018). On splitting training and validation set: A comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of supervised Learning. *Journal of Analysis and Testing*, 2, 249 – 262.

ANEXOS

A1. Información de estaciones utilizadas

<i>Código</i>	<i>Nombre</i>	<i>Altitud (m.s.n.m.)</i>	<i>Latitud norte</i>	<i>Longitud Oeste</i>	<i>Registro inicial</i>	<i>Registro final</i>
100035	COTO 47	8	613558,2	950392,0	ene-80	jun-12
100651	COTO 49, CIUDAD NEILY	28	613725,8	954538,5	ene-16	may-19
69515	QUEBRADA AZUL	83	448265,2	1150390,7	ene-80	oct-19
69537	LA SELVA DE SARAPIQUI	40	499695,9	1153455,1	ene-80	oct-19
69556	SAN VICENTE, CIUDAD QUESADA	1640	458073,8	1137596,8	ene-80	sep-19
69591	SAN JORGE, LOS CHILES	55	426319,2	1185149,0	ene-80	dic-09
69713	SAINT GEORGE, LOS CHILES	87	426151,7	1191466,4	ene-16	sep-09
72101	NICOYA EXTENSION AGRICOLA	120	340850,5	1122197,6	ene-80	nov-13
72165	NICOYA CENTRO	130	340850,5	1122197,6	ene-16	may-19
72106	SANTA ROSA (PARQ. NAL)	315	323095,9	1198718,1	ene-80	jul-15
72163	SANTA ROSA, CC	315	322928,3	1199244,7	ene-16	oct-19
72111	PAQUERA	15	397102,6	1086195,7	ene-80	ago-19
73010	CATIE	602	540229,7	1092911,3	ene-80	dic-15
73155	SITIO DE MATAS, TURRIALBA	800	541007,8	1092503,3	ene-16	may-19
73035	NAVARRO, CARTAGO	1100	513985,9	1084211,4	ene-80	sep-19
73091	HACIENDA EL CARMEN	15	557033,1	1127940,3	ene-80	ene-14
73159	FINCA EL CARMEN, SIQUIRRES	18	556841,7	112784,3	ene-16	sep-19
74008	PELON DE LA BAJURA	40	345461,8	1159792,4	ene-80	oct-19
74020	LLANO GRANDE, LIBERIA	80	331501,6	1172335,6	ene-80	jul-17
76002	TILARAN	562	396497,5	1160953,3	ene-80	dic-06
77002	LA LOLA		567603,6	1116889,5	ene-80	dic-12
80002	SAN MIGUEL DE BARRANCA	140	422953,8	1105826,3	ene-80	dic-07
80013	SAN MIGUELITO DE BARRANCA	120	422919,0	1105826,6	ene-16	ago-19
81003	LIMON	5	606935,4	1101723,6	ene-80	nov-19
82001	GUADALUPE DE ESPARZA	400	437329,5	1106597,3	ene-80	ago-19
84001	SAN JOSE	1172	490862,4	1098372,3	ene-80	dic-95
84141	IMN, ARANJUEZ	1172	492355,0	1098863,5	ene-98	oct-19
84003	LA ARGENTINA, GRECIA	760	461542,0	1109113,4	ene-80	oct-15
84019	HDA. LA LAGUNA, CURRIDABAT	1240	498477,0	1097080,9	ene-80	sep-19
84021	AEROP. JUAN SANTAMARIA	932	478074,3	1105750,9	ene-80	dic-03
84169	AEROP. JUAN SANTAMARIA, MEDIA PISTA	913	476459,6	1104707,4	ene-99	oct-19
84059	LA LUISA, SARCHI	1250	462709,4	1119004,6	ene-80	abr-19
85012	HITTOY CERERE	100	607514,3	1070323,9	jun-81	sep-19
90009	DAMAS, QUEPOS	6	476455,4	1049931,7	ene-84	nov-19
96002	HACIENDA BARU	5	513000,6	1025043,3	ene-81	ago-19
98009	REPUNTA	580	538083,9	1027670,9	ene-80	dic-15
98097	MONTECARLO, PZ	1005	543838,2	1034744,2	ene-16	may-19

Fuente: Instituto Meteorológico Nacional

A2. Tercer EOF del campo de la precipitación en Costa Rica

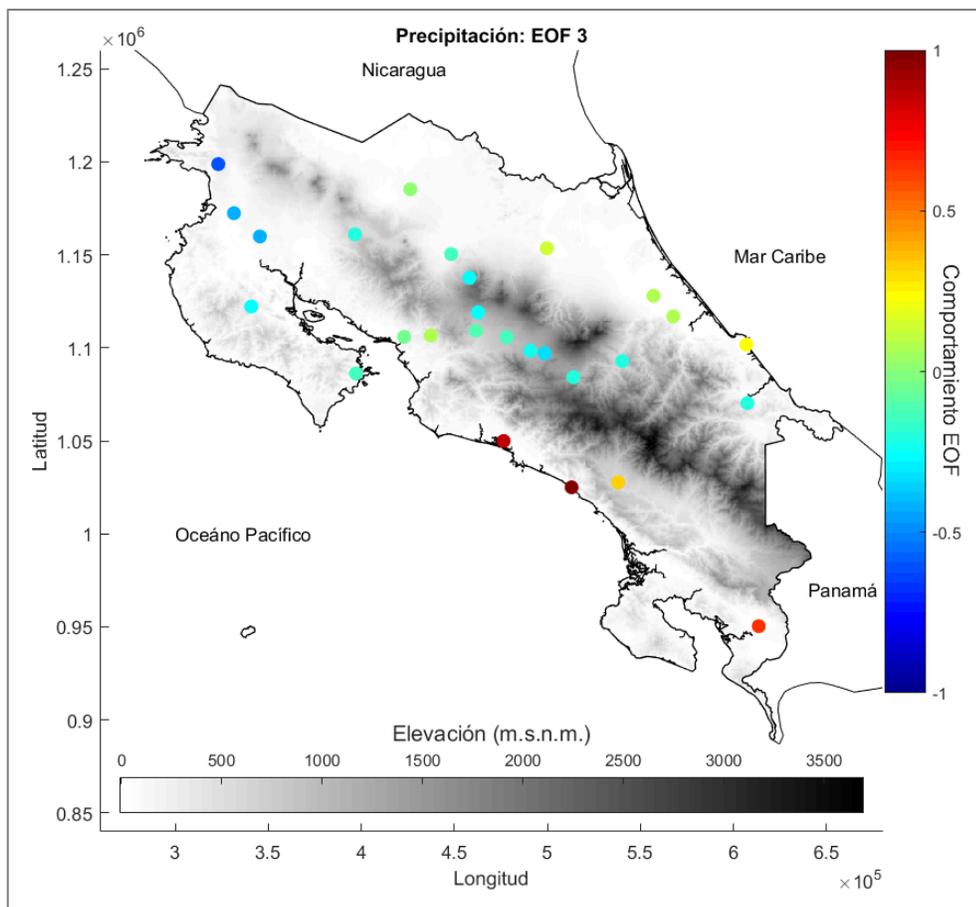


Figura A 1. Comportamiento espacial del tercer EOF del campo de la precipitación

A3. Reconstrucción de las series de precipitación

En la Figura A 2 y en la Figura A 3 se muestra la variación espacial del coeficiente de determinación (R^2) entre las series observadas de precipitación y las series reconstruidas a partir del modo caribe y el modo pacífico, respectivamente. Finalmente, en la Figura A 4 se muestra el caso en el que se utilicen los dos modos de manera simultánea. Al utilizar solamente el modo caribe, los mejores ajustes se presentan en las regiones Caribe (cercano a la costa), Valle Central y Norte, mientras que es a lo largo de la vertiente pacífica donde aparecen los valores más bajos de R^2 . Por su parte, al usar solamente el modo pacífico, se obtiene un comportamiento opuesto, ya que los peores ajustes se muestran en las regiones Caribe y Norte, mientras que a lo largo de la vertiente pacífica y en el Valle Central se presentan los valores de R^2 más altos. A partir de dichos resultados se puede ver que, en general, cada uno de los EOF de precipitación, de manera independiente, representa adecuadamente la variabilidad de la precipitación en cada una de las vertientes de Costa Rica.

A partir de los resultados de la Figura A 2 y en la Figura A 3 se puede ver también que el modo caribe, al ser el modo predominante, representa una mayor parte del comportamiento de la vertiente pacífica que lo que logra representar el modo pacífico de la variabilidad de la precipitación en la vertiente caribe.

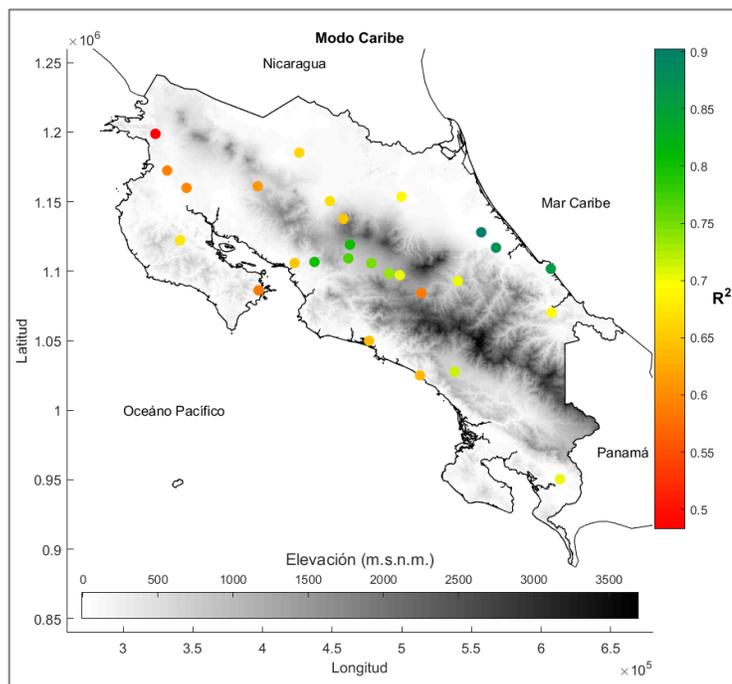


Figura A 2. Variación espacial del R^2 entre las series de precipitación observadas y las series reconstruidas a partir del EOF 1

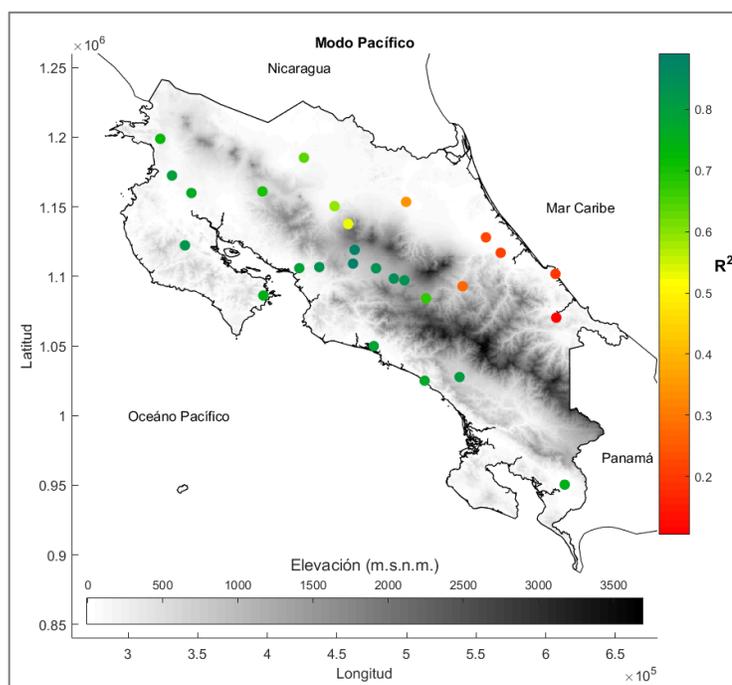


Figura A 3. Variación espacial del R^2 entre las series de precipitación observadas y las series reconstruidas a partir del EOF 2

Adicionalmente, observando la Figura A 4, se puede ver que la mejora en el ajuste entre las series observadas y las reconstruidas, utilizando los primeros dos EOF de manera simultánea, no es significativa. Esto se puede corroborar más fácilmente comparados los correspondientes valores numéricos, los cuales se detallan en la Por lo tanto, se puede concluir que es apropiado trabajar de manera independiente cada EOF de precipitación, tanto para la construcción de los modelos de regresión como para la elaboración de los pronósticos que se deriven de dichos modelos.

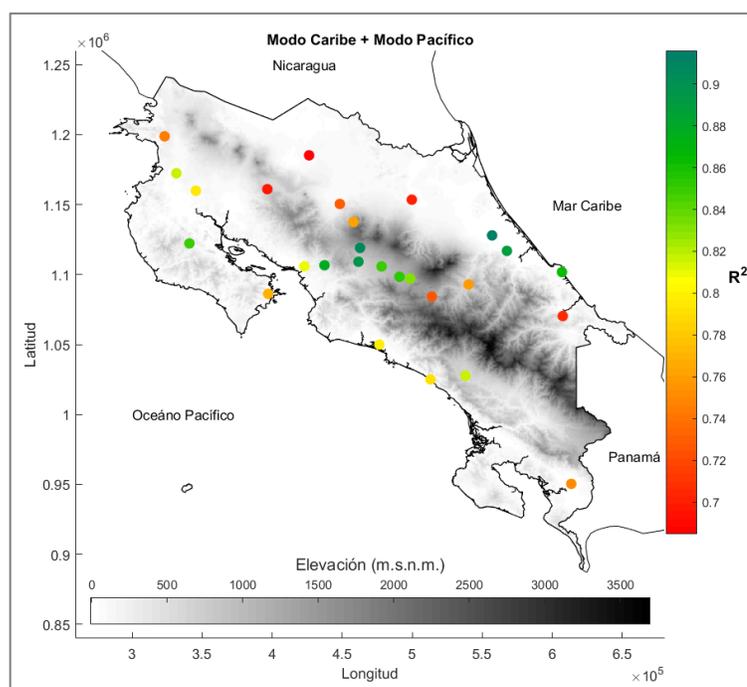


Figura A 4. Variación espacial del R^2 entre las series de precipitación observadas y las series reconstruidas a partir de los primeros dos EOF

Tabla A 1. Valores de R2 según el EOF utilizado para la reconstrucción de las series de precipitación

<i>Vertiente</i>	<i>Estación</i>	<i>Modo Caribe</i>	<i>Modo Pacífico</i>	<i>Modo Caribe + Modo Pacífico</i>
<i>Pacífica</i>	100035	0,70	0,75	0,75
<i>Caribe</i>	69515	0,67	0,59	0,73
<i>Caribe</i>	69537	0,69	0,34	0,70
<i>Caribe</i>	69556	0,65	0,52	0,76
<i>Caribe</i>	69591	0,66	0,64	0,68
<i>Pacífica</i>	72101	0,68	0,82	0,85
<i>Pacífica</i>	72106	0,48	0,72	0,75
<i>Pacífica</i>	72111	0,59	0,75	0,77
<i>Caribe</i>	73010	0,70	0,28	0,76
<i>Pacífica</i>	73035	0,58	0,67	0,73
<i>Caribe</i>	73091	0,90	0,22	0,92
<i>Pacífica</i>	74008	0,60	0,76	0,79
<i>Pacífica</i>	74020	0,59	0,79	0,82
<i>Pacífica</i>	76002	0,61	0,70	0,70
<i>Caribe</i>	77002	0,87	0,21	0,89
<i>Pacífica</i>	80002	0,65	0,78	0,81
<i>Caribe</i>	81003	0,86	0,19	0,86
<i>Pacífica</i>	82001	0,80	0,84	0,88
<i>Pacífica</i>	84001	0,73	0,85	0,85
<i>Pacífica</i>	84003	0,76	0,88	0,90
<i>Pacífica</i>	84019	0,70	0,83	0,83
<i>Pacífica</i>	84021	0,75	0,83	0,85
<i>Pacífica</i>	84059	0,80	0,89	0,91
<i>Caribe</i>	85012	0,70	0,11	0,70
<i>Pacífica</i>	90009	0,64	0,79	0,80
<i>Pacífica</i>	96002	0,63	0,78	0,79
<i>Pacífica</i>	98009	0,72	0,82	0,82

A4. Correlación temporal de la precipitación con índices oceánicos y atmosféricos

En el presente análisis se estimó la correlación lineal entre los modos de precipitación caribe y pacífico y diferentes índices oceánicos y atmosféricos. El análisis se llevó de la misma manera que con los EOF de SST y SLP, es decir, haciéndolo de manera separada para cada mes y considerando un desfase temporal de hasta 7 meses, en el cual el índice en cuestión anticipaba a la precipitación.

Para el análisis se consideraron algunos de los índices asociados con el comportamiento atmosférico y oceánico de ENOS, debido a la influencia que tiene sobre la precipitación de Costa Rica (Waylen 1996; Instituto Meteorológico Nacional, 1998). Se usaron específicamente los índices SOI, Nino 1+2, Nino 3, Nino 4, Nino 3.4, ONI y BEST (Valdés-Pineda, 2014). Adicionalmente, se consideraron los índices oceánicos TNA, AMO y PDO por la influencia que han mostrado tener en la variabilidad de la precipitación del istmo centroamericano (Fallas y Alfaro, 2012; Maldonado et al, 2018).

En la Tabla A 2 y en la Tabla A 3 se muestran, para el modo caribe y el modo pacífico, respectivamente, las máximas correlaciones, el desfase en el que se presentan y el correspondiente índice asociado a dicha correlación.

Tabla A 2. Máximas correlaciones lineales del modo caribe para cada mes con los índices considerados

<i>Mes</i>	<i>Máxima correlación</i>	<i>Desfase (meses)</i>	<i>Índice</i>
<i>Enero</i>	-0,40	6	AMO
<i>Febrero</i>	-0,34	1	TNA
<i>Marzo</i>	-0,37	7	Nino3
<i>Abril</i>	-0,24	6	SOI
<i>Mayo</i>	-0,43	1	Nino4
<i>Junio</i>	-0,27	3	AMO
<i>Julio</i>	-0,53	1	Nino3
<i>Agosto</i>	-0,57	1	ONI
<i>Septiembre</i>	0,51	6	AMO
<i>Octubre</i>	-0,39	7	Nino1-2
<i>Noviembre</i>	0,51	4	PDO
<i>Diciembre</i>	0,36	3	PDO

Tabla A 3. Máximas correlaciones lineales del modo pacífico para cada mes con los índices considerados

<i>Mes</i>	<i>Máxima correlación</i>	<i>Desfase (meses)</i>	<i>Índice</i>
<i>Mayo</i>	0,46	3	Nino 3-4
<i>Junio</i>	-0,39	1	ONI
<i>Julio</i>	0,60	5	TNA
<i>Agosto</i>	-0,62	1	Nino3
<i>Septiembre</i>	-0,67	1	Nino4
<i>Octubre</i>	-0,45	2	ONI

A5. Cuantificación de la habilidad de pronóstico por medio del RAE y Sesgo

Tabla A 4. RAE de los modelos de regresión y los modelos de referencia del modo pacífico

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Mayo</i>	1,29	1,43	1,56	7
<i>Junio</i>	1,13	1,14	1,14	2
<i>Julio</i>	1,25	1,11	1,80	2
<i>Agosto</i>	1,28	1,13	0,76	1
<i>Septiembre</i>	1,37	1,46	1,21	1
<i>Octubre</i>	1,19	1,07	1,27	1

Tabla A 5. RAE de los modelos de regresión y los modelos de referencia del modo caribe

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Julio</i>	1,22	1,33	1,65	2
<i>Agosto</i>	0,57	0,79	0,59	4
<i>Septiembre</i>	0,73	0,77	1,08	5
<i>Octubre</i>	1,17	1,16	1,74	4
<i>Noviembre</i>	1,02	0,78	0,81	7
<i>Diciembre</i>	0,99	0,94	1,37	2

Tabla A 6. Sesgo de los modelos de regresión y los modelos de referencia del modo pacífico

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Mayo</i>	35,32	89,75	21,70	7
<i>Junio</i>	30,84	8,20	-5,31	2
<i>Julio</i>	-7,56	-0,16	-88,70	2
<i>Agosto</i>	-53,84	-27,51	-35,43	1
<i>Septiembre</i>	52,13	5,11	31,48	1
<i>Octubre</i>	-24,66	74,93	67,60	1

Tabla A 7. Sesgo de los modelos de regresión y los modelos de referencia del modo caribe

<i>Mes</i>	<i>Regresión</i>	<i>Climatología</i>	<i>Persistencia</i>	<i>Desfase campo de predictores</i>
<i>Julio</i>	26,40	93,72	93,93	2
<i>Agosto</i>	44,51	-36,25	-1,70	4
<i>Septiembre</i>	-16,27	-23,40	13,80	5
<i>Octubre</i>	36,31	41,88	13,45	4
<i>Noviembre</i>	-121,08	-13,03	31,21	7
<i>Diciembre</i>	93,77	-81,71	-126,47	2

A6. Análisis de varianza de los modelos de regresión

En las siguientes cuatro tablas se muestran los análisis de varianza (ANOVA) de los cuatro modelos de regresión considerados para la realización de los pronósticos de precipitación. En cada tabla se detallan la cantidad de datos (n), la cantidad de parámetros del modelo (k), la suma de cuadrados de la regresión (SSR), la suma de cuadrados del error (SSE) y el correspondiente valor del estadístico F, el cual para todos los casos es superior al valor teórico de la distribución F para un nivel de confianza del 95%. Por lo tanto, todos los modelos de regresión poseen significancia estadística.

Tabla A 8. ANOVA para el modelo Mayo-Pacífico

Fuente de variación	Grados de libertad	Suma de cuadrados	Valor medio de la suma de cuadrados	Coficiente F
Total	$n = 35$	SST		MSR/MSE = 11,48
Regresión	$k = 4$	SSR = 0,5973	MSR = 0,1493	
Residuos	$n-k = 31$	SSE = 0,4022	MSE = 0,0130	

F teórico = 2,679

Tabla A 9. ANOVA para el modelo Julio-Caribe

Fuente de variación	Grados de libertad	Suma de cuadrados	Valor medio de la suma de cuadrados	Coficiente F
Total	$n = 36$	SST		MSR/MSE = 9,34
Regresión	$k = 4$	SSR = 0,5381	MSR = 0,1345	
Residuos	$n-k = 32$	SSE = 0,4619	MSE = 0,0144	

F teórico = 2,668

Tabla A 10. ANOVA para el modelo Agosto-Caribe

Fuente de variación	Grados de libertad	Suma de cuadrados	Valor medio de la suma de cuadrados	Coficiente F
Total	$n = 36$	SST		MSR/MSE = 9,83
Regresión	$k = 3$	SSR = 0,4718	MSR = 0,1573	
Residuos	$n-k = 33$	SSE = 0,5282	MSE = 0,016	

F teórico = 2,892

Tabla A 11. ANOVA para el modelo Septiembre-Caribe

Fuente de variación	Grados de libertad	Suma de cuadrados	Valor medio de la suma de cuadrados	Coficiente F
Total	n = 36	SST		MSR/MSE = 18,46
Regresión	k = 3	SSR = 0,6258	MSR = 0,2086	
Residuos	n-k = 33	SSE = 0,3742	MSE = 0,0113	

F teórico = 2,892