



COLEGIO DE POSTGRADUADOS

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN
EN CIENCIAS AGRÍCOLAS

SOCIOECONOMÍA, ESTADÍSTICA E INFORMÁTICA
ESTADÍSTICA

CAMPUS MONTECILLO

**MODELACIÓN ESTADÍSTICA DE LA
RELACIÓN DE LA SEQUÍA Y EL ENSO
EN EL ALTIPLANO MEXICANO**

LIZETH MARGARITA LECHUGA GAYOSSO

T E S I S

PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:

MAESTRA EN CIENCIAS

MONTECILLO, TEXCOCO, ESTADO DE MÉXICO

2020

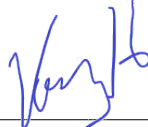
La presente *tesis* titulada: "**Modelación Estadística de la relación de las sequías y el ENSO en el Altiplano Mexicano.**", realizada por el alumno: *Lizeth Margarita Lechuga Gayosso*, bajo la dirección del *Consejo Particular* indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS

SOCIOECONOMÍA, ESTADÍSTICA E INFORMÁTICA ESTADÍSTICA


CONSEJO PARTICULAR:

CONSEJERO




Dr. Humberto Vaquera Huerta

ASESOR



Dra. Elizabeth González Estrada

ASESOR



Dr. Jesús David Gómez Díaz

MONTECILLO, TEXCOCO, ESTADO DE MÉXICO

JUNIO DE 2020

MODELACIÓN ESTADÍSTICA DE LA RELACIÓN DE LAS SEQUÍAS Y EL ENSO EN EL ALTIPLANO MEXICANO.

Lizeth Margarita Lechuga Gayosso

COLEGIO DE POSTGRADUADOS, 2020

RESUMEN

La sequía hídrica afecta de manera considerable la mayoría de las actividades productivas del hombre, en el presente trabajo se realiza el análisis de la precipitación en el Altiplano Mexicano (centro norte), por medio de los índices oceánico-atmosféricos utilizando , con el fin de obtener los periodos de retorno para que el requerimiento hídrico mínimo del cultivo de frijol de temporal se satisfaga. En estudios previos se han utilizado modelos lineales clásicos (regresión y análisis de varianza), y donde se utiliza el modelo de la distribución normal como un supuesto distribucional el cual es difícil de satisfacer en el caso de la variable precipitación. En este trabajo se propone el uso de los modelos: Modelo Lineal Generalizado (GLM), Modelo Lineal Generalizado Vectorizado (VGAM) y Modelos aditivos generalizados para localidad, escala y forma (GAMLSS), utilizando para las distribuciones de valores extremos (GEV) para VGAM, beta generalizada tipo II (GB2), gamma generalizada (GG) y gamma (G) para GAMLSS, teniendo como variable respuesta la precipitación y variables explicatorias los índices oceánico-atmosféricos. Para encontrar el mejor modelo se utilizó el criterio de información de Akaike (AIC) del modelo y también se empleó la validación cruzada en una proporción de 70/30 para evaluar el comportamiento predictivo del modelo. Los resultados nos muestran para este estudio que el modelo VGAM con la distribución GEV ajustó mejor a los datos de la región y con dicho modelo se calcularon las probabilidades y los periodos de retorno que se colocaron en un mapa de contornos por medio del sistema de información geográfica QGIS.

Palabras clave: precipitación, ENSO, VGAM, GAMLSS, GEV

STATISTICAL MODELING OF THE RELATIONSHIP BETWEEN
DROUGHTS AND ENSO IN THE MEXICAN ALTIPLANO.

Lizeth Margarita Lechuga Gayosso

POSTGRADUATE COLLEGE, 2020

ABSTRACT

The hydric drought considerably affects the majority of the productive human activities. In this work, the analysis of precipitation in the Mexican Altiplano (north and center) is carried out, by the use of the oceanic-atmospheric indices, in order to obtain the return periods of so that the minimum water requirement of the seasonal bean crop is satisfied. In previous studies, classical linear models have been used (regression and analysis of variance), where the normal distribution model is used as a distributional assumption which in most of cases is difficult to satisfy for the precipitation variable. In this work it is proposed the use of the models: Generalized Linear Model (GLM), Vectorized Generalized Linear Model (VGAM) and Generalized additive models for locality, scale and shape (GAMLSS), by using for extreme value distributions (GEV) to VGAM, and the generalized beta type II (GB2), generalized gamma (GG) and gamma (G) for GAMLSS, having as response variable the precipitation and explanatory variables the oceanic-atmospheric indices. For model selection, the Akaike information criterion (AIC) was used, and a cross-validation (in a 70/30 ratio) was also used to evaluate the predictive behavior of the models. The results shows that the VGAM model with the GEV distribution had the best fitting to data of the study region and with VGAM model the probabilities and return periods were calculated and placed on a contour map using the Geographic Information System QGIS.

Key words: precipitation, ENSO, VGAM, GAMLSS, GEV

DEDICATORIA Y AGRADECIMIENTOS

A mis padres, que siempre han apoyado mis decisiones.
A mis hermanas, que me han aportado días de diversión y cariño sincero.
A los sobrinos, por siempre traer alegrías.

Al Dr. Vaquera por sus consejos y su gran paciencia para una estudiante no versada en la estadística y la programación.

Al Dr. Gomez Díaz por mostrarme el noble camino de la ciencia, por mostrarme a una persona comprometida con la profesión que ama.

A la Dra. Elizabeth por su infinita paciencia para explicar y los buenos momentos pasados en clase.

A todos los profesores por hacer mi estancia en el Área de Estadística una experiencia amena e interesante, una disculpa si no los dejaba concentrarse en su trabajo por los "momentos divertidos".

A todos los administrativos que ayudaron a esta estudiante por los intrincados caminos de la burocracia en la institución y por sus agradables sonrisas, en especial, a Isa, Gris, Gus, Juan y Laurita.

A Ricardo por ayudar a esta inexperta en programación a eficientar sus códigos, tu apoyo es invaluable.

A Lau, Rod, Abel y Yamil, mis compañeros en la aventura de la maestría, por traer muchos días de diversión y estar en los momentos difíciles.

Lizeth Margarita Lechuga Gayosso

JUNIO, 2020

CONTENIDO

	Página
RESUMEN	iii
ABSTRACT	iv
LISTA DE FIGURAS	x
LISTA DE CUADROS	xii
1. INTRODUCCIÓN	1
2. JUSTIFICACIÓN	3
3. OBJETIVOS	5
3.1. General	5
3.2. Particulares	5
4. MARCO TEÓRICO	6
4.1. La sequía	6
4.1.1. Definiciones	6
4.1.2. Factores que influyen en la precipitación en México	6
4.1.3. Escala de tiempo de la sequía	7
4.2. Índices climáticos	7
4.2.1. El Niño-Oscilación del Sur (ENSO)	7
4.2.1.1. Índice Oceánico del Niño	8
4.2.2. Oscilación del Pacífico Norte (NPO)	10
4.2.2.1. Índice del Pacífico Norte (NPI)	11
4.2.3. Oscilación Decadal del Pacífico (PDO)	11
4.2.3.1. Índice de la Oscilación Decadal del Pacífico (PDO Index)	11
4.2.4. Oscilación del Atlántico Norte (NAO)	12

CONTENIDO

4.2.4.1.	Índice mensual de la Oscilación del Atlántico Norte(NAO Index)	13
4.2.5.	La Oscilación Multidecenal del Atlántico (AMO)	14
4.2.6.	Sistema Aleutiano de Baja Presión atmosférica	15
4.3.	Generalidades del Altiplano Mexicano	16
4.4.	Cultivo del frijol (<i>Phaseolus vulgaris L.</i>)	18
4.4.1.	Generalidades	18
5.	MODELACION ESTADISTICA:FUNDAMENTOS TEÓRICOS	19
5.1.	Modelos probabilísticos para la precipitación	19
5.1.1.	Distribución Gamma	19
5.1.2.	Distribución Gamma Generalizada	20
5.1.3.	Distribución Beta Generalizada tipo II	21
5.1.4.	Distribuciones de Valores Extremos	23
5.1.4.1.	Teoría del Valor Extremo	23
5.1.4.2.	Distribución del máximo	23
5.2.	Modelos estadísticos en datos de precipitación	25
5.2.1.	Modelos Lineales Generalizados (GLM)	25
5.2.2.	Modelos aditivos	26
5.2.2.1.	Estimación de ecuaciones para los modelos aditivos	27
5.2.2.2.	Regresión por partes penalizada como representación de un modelo aditivo	27
5.2.2.3.	Ajuste del modelo aditivo por mínimos cuadrados penalizados	28
5.2.2.4.	Modelos aditivos generalizados (GAM)	29
5.2.2.5.	Modelos aditivos generalizados vectorizados(VGAM)	30
5.2.3.	Modelos aditivos generalizados para localización, escala y forma (GAMLSS)	31
5.3.	Requerimientos hídricos del cultivo del frijol	32
5.3.1.	Estimación de la Evapotranspiración potencial (ET_0)	33
5.3.2.	Estimación del Coeficiente del cultivo simple (k_C)	34
6.	PROPUESTA METODOLÓGICA	36
6.1.	Características de los datos	36
6.1.1.	Precipitación (variable respuesta)	36
6.1.2.	Ubicación, Altitud e Índices Oceánico-Atmosféricos (variables explicatorias)	37
6.2.	Ajuste y selección de modelos probabilísticos a datos de precipitación	37
6.3.	Selección de los modelos	38
6.4.	Selección de las variables explicatorias	38
6.5.	Validación cruzada	39
6.6.	Estimación de probabilidades y tiempos de retorno	39
6.6.1.	Estimación de los cuantiles para obtener sus probabilidades (Evapotranspiración del cultivo de frijol [ET_C])	39
6.6.2.	Estimación de las probabilidades y los tiempos de retorno	40

CONTENIDO

6.6.2.1.	Estimación de los cuantiles	40
6.6.2.2.	Estimación de las probabilidades y periodos de retorno	40
6.6.2.3.	Generación de mapas con las probabilidades y los tiempos de retorno	41
7.	RESULTADOS	42
7.1.	Estaciones meteorológicas consideradas en el estudio	42
7.2.	Ajuste de las distribuciones G, GG, GB2 y GEV	43
7.2.1.	Exploración	43
7.2.2.	Ajuste de distribución	43
7.3.	Selección de Modelos y Variables	45
7.3.1.	Selección de Modelos	45
7.3.2.	Selección de Variables	46
7.3.2.1.	Modelo VGAM GEV	46
7.3.2.2.	Modelo GAMLSS GB2	49
7.3.2.3.	Modelo GAMLSS Gamma Generalizada	52
7.3.2.4.	Modelo GAMLSS Gamma	53
7.3.3.	Comparación entre modelos	56
7.4.	Probabilidades y periodos de retorno	57
7.4.1.	Estimación de cuantiles	57
7.4.2.	Estimación de probabilidades y periodos de retorno	58
7.4.2.1.	Escenario 1	58
7.4.2.2.	Escenario 2	58
7.4.3.	Mapas de periodos de retorno	59
7.4.3.1.	Escenario 1	59
7.4.3.2.	Escenario 2	61
8.	CONCLUSIONES	64
	LITERATURA CITADA	64
A.	CÓDIGOS	72
A.1.	Codigo VBA	72
A.1.1.	Acomodo de datos originales	72
A.1.2.	Obtención de valores únicos	77
A.1.3.	Obtención de los valores de NA	82
A.1.4.	Obtención de los datos analizados	84
A.2.	Códigos SAS	87
A.2.1.	Distribución de los datos de precipitación por estación	87
A.3.	Códigos R	90
A.3.1.	Selección de las distribuciones	90
A.3.2.	Cálculo de ETC del cultivo del frijol	95
A.3.3.	Selección de los modelos, las variables, Validación Cruzada, Estimación de probabilidades y tiempos de retorno por estación	97
A.3.3.1.	Modelo VGAM GEV	97

CONTENIDO

A.3.3.2. Modelos GAMLSS Beta Generalizada tipo II (GB2),
Gamma Generalizada (GG) y Gamma (GA) 108

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS UTI-
LIZADAS EN EL PRESENTE ESTUDIO 122**

LISTA DE FIGURAS

Figura 4.1:	Circulación de los vientos en a) año normal y b) año Niño (Ahrens (2009))	8
Figura 4.2:	Cambios en el clima en un año Niño en comparación con un año normal a) En Diciembre-Enero b) En Junio-Agosto (Ahrens (2009))	9
Figura 4.3:	Ubicación de la región Niño 3-4 (L’Heureux et al. (2013)) . .	9
Figura 4.4:	Gráfica de los valores de ONI de 1998-2019 (NOAA-ESRL (2020))	10
Figura 4.5:	Diferencia en la precipitación media de Enero para AB menos AA de 1906 a 1980. (Rogers (1981))	10
Figura 4.6:	a) Fase cálida y b) Fase fría del PDO (Ahrens (2009)) . . .	11
Figura 4.7:	Gráfica del PDO index de 1900 al 2017 (JISAO (2017)) . . .	12
Figura 4.8:	Fase positiva y b) Fase negativa del NAO durante el invierno Ahrens (2009)	13
Figura 4.9:	Gráfica del NAO index de 1900 al 2019 Hurrell et al. (2013)	13
Figura 4.10:	Patrón de circulación termohalina del Atlántico Simmon (2008)	14
Figura 4.11:	Temperatura media global entre 1880-2009 en comparación con el índice de oscilación atlántica multidecadal (AMO) Trenberth (2019)	14
Figura 4.12:	Locaciones geográficas del centro de ALP de 1900-2015 (Surry and King (2015))	15
Figura 4.13:	Índice de Sistema de Baja Presión de las Aleutianas (ALPI) Surry and King (2015)	16
Figura 4.14:	Ubicación de la región del Altiplano Mexicano <i>Elaboración propia</i>	16
Figura 4.15:	Provincias fisiográficas del Altiplano Mexicano (INEGI. (2001))	17
Figura 4.16:	Principales ríos del Altiplano Mexicano (INEGI. (2008)) . .	17
Figura 5.1:	Gráfica de densidad de la GB2 con parámetros $a=(1, 1.5, 2, 3.5)$, $b = 50, p = 5, q = 2$	22

LISTA DE FIGURAS

Figura 5.2:	Familia de distribución Beta Generalizada (GB) (McDonald (2008))	22
Figura 7.1:	Ubicación de las estaciones utilizadas en el presente estudio	42
Figura 7.2:	Función de distribución empírica de los meses de mayo a octubre de la estación 32020 Fresnillo, Zac.	43
Figura 7.3:	Función de distribución empírica y teorica (GA GG GB2 GEV) de los meses de mayo a octubre de la estación 32020 Fresnillo, Zac.	44
Figura 7.4:	Mapas de los periodos de retorno (años) por mes para el escenario 1	60
Figura 7.5:	Mapa de los periodos de retorno (años) con el ciclo de cultivo para el escenario 1	61
Figura 7.6:	Mapas de los periodos de retorno (años) por mes para el escenario 2	62
Figura 7.7:	Mapa de los periodos de retorno (años) con el ciclo de cultivo para el escenario 2	63

LISTA DE CUADROS

Cuadro 4.1. Climas del área de estudio, su área en Ha. y el porcentaje del área total (INEGI (2008))	18
Cuadro 5.1. Duración de las etapas del cultivo del frijol Doorenbos and Pruitt. (1977)	34
Cuadro 5.2. Valores predeterminados de k_C para el periodo de crecimiento del cultivo del frijol Doorenbos and Kassam (1979)	35
Cuadro 6.1. Claves de las estaciones climáticas CONAGUA	37
Cuadro 6.2. Algunas características de los índices oceánico-atmosféricos	37
Cuadro 6.3. Modelos VGAM comparados para cada estación	39
Cuadro 6.4. Modelos GAMLSS comparados para cada estación	39
Cuadro 7.1. Resultados del procedimiento Severity de SAS para la estación 32020 Fresnillo, Zacatecas	43
Cuadro 7.2. AIC y p-valor de la prueba de χ^2 para los modelos VGAM GEV	47
Cuadro 7.3. AIC para los modelos GAMLSS GB2	49
Cuadro 7.4. AIC para los modelos GAMLSS GG	53
Cuadro 7.5. AIC para los modelos GAMLSS G	53
Cuadro 7.6. SCE de los modelos VGAM GEV, GAMLSS GB2 y GAMLSS G	57
Cuadro 7.7. Requerimiento hídrico del cultivo de frijol, estación 32020, fecha de siembra: 15-May	57
Cuadro 7.8. Requerimiento hídrico del cultivo de frijol, estación 32020, fecha de siembra: 15-Jun	57
Cuadro 7.9. Probabilidades calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 1	58
Cuadro 7.10. Periodo de retorno calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 1	58
Cuadro 7.11. Probabilidades calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 2	58

LISTA DE CUADROS

Cuadro 7.12. Periodo de retorno calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 2 59

Cuadro B.1. Estaciones analizadas en el presente estudio 122

CAPÍTULO 1

INTRODUCCIÓN

La sequía es un fenómeno natural que afecta de manera considerable la gran mayoría de las actividades productivas del hombre, el poder determinar la probabilidad de que exista una sequía con antelación permitiría que la toma de decisiones con información sea más fácil para productores y gobiernos, por lo tanto tener un primer acercamiento a un modelo que tome en consideración los índices oceánico-atmosféricos es muy importante, como una base para crear un sistema de predicción de la sequía. En el capítulo 2), se dan mas detalles del tema de la sequía.

En el capítulo 4 se abordan se abordan los temas relacionados a la definición de la sequía y la precipitación, así como los factores que influyen en la precipitación y los tipos de sequía que existen por escala de tiempo, además la descripción de los índices oceánico-atmosféricos, las generalidades de la región del altiplano mexicano y del cultivo del frijol.

En el capítulo 5 se describen las diferentes distribuciones a las que se le ha asociado la precipitación, además de los fundamentos teóricos de los diferentes modelos probados en el presente estudio, además también la teoría relacionada al cálculo de los requerimientos hídricos del cultivo de frijol.

En el primer apartado del capítulo 6 se habla de las características de los datos, en los siguientes apartados, comenta de la metodología seguida para la selección de las distribuciones, así como la selección de modelos y de las variables, en el último apartado se explica la metodología seguida para estimar, los cuantiles (requerimientos del cultivo), las probabilidades y periodos de retorno.

En el capítulo 7 se aplica el método descrito en el capítulo 6, se describen los resultados de la exploración y el ajuste de las distribuciones, así como la selección de modelos y de las variables. Finalmente, se hace una comparación de los modelos y se escoge el que ajuste mejor a la mayoría de las estaciones.

Por último, en el capítulo 8 se encuentran las conclusiones, siendo el modelo VGAM GEV el modelo que ajustó de mejor maneja en la mayoría de los meses, además que se comenta sobre el ajuste de las distribuciones a los datos.

El apéndice A se muestran todos los códigos utilizados, desde los códigos para la

1. INTRODUCCIÓN

selección de los datos en VBA, pasando por el código de exploración de las distribuciones, y los códigos utilizados en R para la selección de modelos y de las variables, así como la estimación de los cuantiles, las probabilidades y los periodos de retorno. Mientras el apéndice [B](#) muestra el total de las estaciones analizadas en el presente estudio y de las cuales se obtuvieron las conclusiones.

CAPÍTULO 2

JUSTIFICACIÓN

La sequía es uno de los desastres climáticos más frecuentes que ocurren en grandes partes del mundo, a menudo con consecuencias devastadoras para la seguridad alimentaria de los productores de zonas rurales dedicados a actividades de agricultura y ganadería (Rojas (2020)). La sequía en México ha sido relacionada con el fenómeno meteorológico conocido como El Niño, que estuvo fuertemente relacionado con la sequía de 1982-1983, dejando pérdidas importantes en todos los sectores. Existe evidencia de la relación entre sequías y la presencia del fenómeno del Niño (María Engracia Hernández and Alfaro (2007),). Las fases de dominancia de El Niño/La Niña explican la mayor parte de la variación en las áreas agrícolas afectadas por la sequía de acuerdo a Rojas (2020). La intensidad de la sequía no necesariamente está asociada a la intensidad del Niño, por lo que se han asociado dichas variaciones a otros fenómenos oceánico-atmosféricos (4.2) que pueden amortiguar o aumentar la posibilidad de tener sequías más intensas.

Una de las actividades productivas más afectadas por la sequía son la producción de cultivos, es decir, la agricultura, lo cual pone en riesgo la seguridad alimentaria de una región y la presencia de hambrunas. En México, tiene agricultura de riego y de temporal, la agricultura de riego le permite tener un "seguro" contra las sequías que son de corta duración (sequías agrícolas), además de estar más tecnificada lo cual permite un mejor uso del agua, sin embargo, la agricultura de temporal tiene serios problemas si la precipitación no llega en los momentos necesarios que el cultivo requiere para ser productivo y sea rentable, que además de ser característico de pequeños productores, de la rentabilidad de su cultivo mantienen a sus familias, en especial, en una de las regiones que más le afecta la sequía en el país, como lo es el Altiplano Mexicano. En el Altiplano Mexicano uno de los principales cultivos es el frijol para climas templados, que es un grano básico y alimento fundamental en la gastronomía mexicana y consumido por la mayor parte de la población mexicana.

Debido a lo anteriormente descrito, la importancia de predecir la sequía es fundamental para poder hacer una planeación de los limitados recursos que se tienen, para evitar que la mayor cantidad de afectaciones posibles relacionadas a este evento meteorológico.

2. JUSTIFICACIÓN

El presente trabajo estudia una propuesta metodológica para contribuir en la creación un sistema de alerta temprana de sequías para México, mediante la obtención los periodos de retorno para que el requerimiento hídrico mínimo del cultivo de frijol de temporal se satisfaga en el Altiplano mexicano, por medio de modelos espacio-temporales, que tengan los índices oceánico-atmosféricos, ya que, existen proyecciones de estos índices de hasta por 6 meses ([NCEP\(2020\)](#)).

CAPÍTULO 3

OBJETIVOS

3.1. General

- Obtener el periodo de retorno para que el requerimiento hídrico mínimo del cultivo de frijol de temporal se satisfaga en el Altiplano mexicano, representar por medio de mapas dicho periodo, con el fin de generar la base para crear un sistema de alerta temprana de sequías para México.

3.2. Particulares

- Calcular los requerimientos hídricos del cultivo del frijol para cada una de las estaciones meteorológicas de la zona de estudio, por medio del método establecido por la FAO, que fungirán como cuantiles.
- Determinar las distribuciones probabilísticas que tienen un mejor ajuste a los datos de precipitación de las estaciones del Altiplano Mexicano.
- Encontrar la relación entre la precipitación y los índices oceánico-atmosféricos, por medio del uso de modelos espacio-temporales, para cada estación de la región.
- Calcular las probabilidades y los periodos de retorno, por medio de los modelos y los cuantiles, para obtener las estaciones donde es viable producir frijol considerando únicamente sus condiciones hídricas, para cada estación de la región.
- Generar programas computacionales útiles para estudios de sequía en México.

CAPÍTULO 4

MARCO TEÓRICO

4.1. La sequía

4.1.1. Definiciones

Cuando se presenta un evento sin precipitación pluvial, el cual ocurre en una región que se caracteriza por tener precipitaciones abundantes, dicho evento es conocido como sequía (Landsberg (1982); Piechota and Dracup (1996)). La sequía tiene como característica que la precipitación presentada es temporalmente menor que la precipitación promedio, influyendo en todos los procesos tanto ecológicos como en las actividades productivas del hombre. (Piechota and Dracup (1996); Felch (1978))

La precipitación es el agua procedente de la atmósfera que, ya sea en forma sólida o líquida, se deposita sobre la superficie de la Tierra, su comportamiento depende de la localización de los centros de alta y baja presión con respecto a la región, el relieve y si la atmósfera está inestable. Ahrens (2009).

Entre las causas de las sequías Felch (1978) explica que el factor con más peso en la prolongación de la sequía es la ausencia en gran escala del movimiento vertical del aire, es decir, el viento que genera las lluvias, y esta es ocasionada por anomalías en el sistema de circulación en los patrones de onda larga y por la debilidad de la zona intertropical de convergencia.(Landsberg (1982))

4.1.2. Factores que influyen en la precipitación en México

En México, la precipitación presenta mucha variabilidad,esto es en parte por la intrincada orografía del país, además está influenciada por los huracanes y tormentas tropicales, y en muchas partes del país su mayor precipitación proviene de éstas, principalmente para el centro-sur del país,sin embargo, es un fenómeno que tiene mucha variabilidad , además de que su efecto cambia dependiendo de su posición en el tiempo y espacio tanto de la tormenta tropical como de la estación, además que presentan variabilidad en la intensidad y frecuencia debido a los índices climáticos como el ENSO (El Niño-Oscilación del Sur) y el AO (Oscilación del Ártico). (Wallén (1955); Magaña

4.2. Índices climáticos

[et al. \(2003\)](#); [Larson et al. \(2005\)](#))

Para el Altiplano Mexicano parte de la precipitación se genera un sistema regional de vientos conocido como Monzón de Norteamérica, provocando la mayor cantidad de precipitaciones en verano([CPC-NOAA \(2004\)](#); [García and Trejo \(1994\)](#)), la zona oriente del Altiplano también es influenciado por los vientos alisios provenientes del Golfo de México, otro sistema regional de vientos.([García and Trejo \(1994\)](#)) Ambos sistemas son afectados por los forzamientos oceánico-atmosféricos.([Chiang and Vimont \(2004\)](#))

Como se ha descrito en los párrafos anteriores,del mismo modo que ocurre a nivel mundial, los cambios en los índices climáticos afectan la precipitación, pero se relatarán el capítulo [4.2](#).

4.1.3. Escala de tiempo de la sequía

Una escala de tiempo, en en el contexto de la sequía, es el periodo de tiempo donde se analiza el comportamiento de la precipitación y se compara con todos los datos de precipitación para determinar si es normal para el tiempo y la ubicación ([Edwards \(1997\)](#)). Esto significa que la definición del tiempo a analizar dependerá de los objetivos a alcanzar. ([Piechota and Dracup \(1996\)](#))

Desde esta perspectiva, [McKee \(1993\)](#) indica que las sequías se pueden clasificar por el tiempo acumulado donde hay déficits de precipitación, ya que diferentes actividades humanas y ecológicas son afectadas de forma diferente, por ejemplo, el déficit de precipitación de 3 meses en la época de lluvias puede impactar a la agricultura pero no a las reservas de agua. ([Kingery \(1992\)](#))

4.2. Índices climáticos

Las interacciones aire-océano, también conocidos como índices climáticos, juegan un papel fundamental en comportamiento de las sequías, el Océano Pacífico y el Océano Atlántico influyen en las precipitaciones y sus anomalías en Norteamérica por medio del modelo general de circulación de la atmósfera. ([Tannehill \(1947\)](#) ; [Oglesby \(1991\)](#) , [Chiang and Vimont \(2004\)](#)). Se ha probado que el ENSO, el AO y más oscilaciones afectan el comportamiento de los factores que influyen en la precipitación ([Gray \(1984\)](#); [Chiang and Vimont \(2004\)](#)). A estos cambios que afectan de manera indirecta a una región se llaman interconexiones. ([Ahrens \(2009\)](#); [McPhaden et al. \(2006\)](#))

4.2.1. El Niño-Oscilación del Sur (ENSO)

El Niño-Oscilación del Sur (ENSO por sus siglas en inglés) es la variabilidad interanual dominante en el Océano Pacífico ([Trenberth and Hurrell \(1994\)](#)), generando el mayor impacto en el comportamiento del periodo de lluvias e involucra el cambio de las temperaturas de las aguas de entre 1 a 3 grados Celsius comparado al normal en la región central y oriental del Océano Pacífico en periodos de tiempo de tres a siete años.

4.2. Índices climáticos




Figura 4.1: Circulación de los vientos en a) año normal y b) año Niño (Ahrens (2009))

La circulación tipo Walker, que es conocida como normal, es una de las corrientes más importantes del Océano Pacífico ya que tienen repercusiones en todo el mundo. Esta circulación consiste en una concentración de aguas cálidas en las costas de la selva de Borneo, la cual genera una zona de vientos ascendentes y tiene precipitaciones muy fuertes y en las regiones de surgencia es una zona de vientos descendentes impidiendo que el aire con humedad se eleve y forme nubes en la región del mar del Perú. (Figura 4.1a). Cada 3 a 7 años, con mucha variabilidad, el motor que genera la circulación normal se detiene, ocasionando sequías en la selva de Borneo y lluvias torrenciales en la región de Perú, siendo conocido como "El Niño-Southern Oscillation" (ENSO) (Figura 4.1b). Cuando la circulación tipo Walker se fortalece, por tener mayor fuerza los vientos alisios, se generan lluvias extraordinarias en las grandes selvas del mundo y mayor sequía en Perú, se le llama "La Niña".

También repercute en todo el mundo, (Figura 4.2) ocasionando graves sequías en los meses de diciembre y enero en las selvas del Amazonas, Madagascar y en Borneo, siendo las más importantes del planeta, lluvias en sur de Estados Unidos y México y lluvias torrenciales en Perú, mientras que en los meses de Junio a Agosto, la sequía se apodera de América Central, Indonesia, la India y las zonas con precipitación se concentran en el Océano Pacífico. (Ahrens (2009))

4.2.1.1. Índice Oceánico del Niño

Como se ha descrito anteriormente, el ENSO el fenómeno variable más importante que influye en el comportamiento de la precipitación a nivel mundial, sin embargo, el océano es más cálido hoy que el promedio a largo plazo, lo cual implicaría que el fenómeno sería permanente, entonces se tuvo que reconsiderar la forma en la que se monitorea y pronostica los eventos de ENSO (L'Heureux et al. (2013)), por lo que se cambió la forma de considerar cual es la temperatura promedio en el Pacífico tropical.

4.2. Índices climáticos

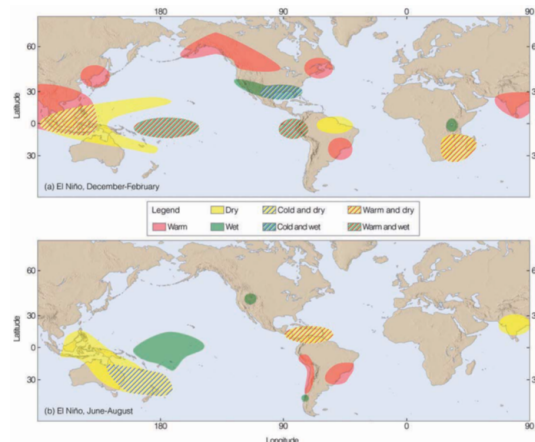


Figura 4.2: Cambios en el clima en un año Niño en comparación con un año normal a) En Diciembre-Enero b) En Junio-Agosto (Ahrens (2009))



Figura 4.3: Ubicación de la región Niño 3-4 (L'Heureux et al. (2013))

Así se determinó que la temperatura promedio (con 30 años de datos) de la región 3-4 del Océano Pacífico, esta se resta con los datos observados. Si la diferencia es más cálida o más fría es usado para indicar la fase del ENSO que se esté presentando. Esta diferencia es conocida como "Índice Oceánico del Niño"(ONI, en inglés). En la figura 4.3 el rectángulo muestra la ubicación del Niño 3-4, esta región se extiende desde la latitud 5N a 5S de latitud y 120W a 170W de longitud. Se considera normal si dicha diferencia está entre 0.5 y -0.5. Si es igual o mayor a 0.5 es periodo de "Niño", si es igual o menor a -0.5 es "Niña".(L'Heureux et al. (2013))

El Índice se ha actualizado constantemente, actualmente está el ERSSTv5, las estimaciones tienen variaciones espacio-temporales más realistas, mejor representación de las temperaturas superficiales del mar (SST, en inglés) de alta latitud, y los sesgos de SST del barco ahora se calculan en relación con una boya con mediciones más precisas, mientras que la tendencia global a largo plazo sigue siendo la misma. (Huang et al. (2018))

4.2. Índices climáticos




Figura 4.4: Gráfica de los valores de ONI de 1998-2019 (NOAA-ESRL (2020))

4.2.2. Oscilación del Pacífico Norte (NPO)

Descubierto por Walker (1932), esta oscilación es la anomalía de las temperaturas medias entre el oeste de Alaska-este de Siberia y el oeste de Canadá. La oposición en las temperaturas de invierno entre el oeste de Alaska, el este de Siberia y el oeste de Canadá, que caracteriza a la NPO, se debe principalmente a los cambios en el posición media del bajo aleutiano con inviernos más cálidos sobre Canadá asociados con un cambio hacia el este del bajo hacia el golfo de Alaska.

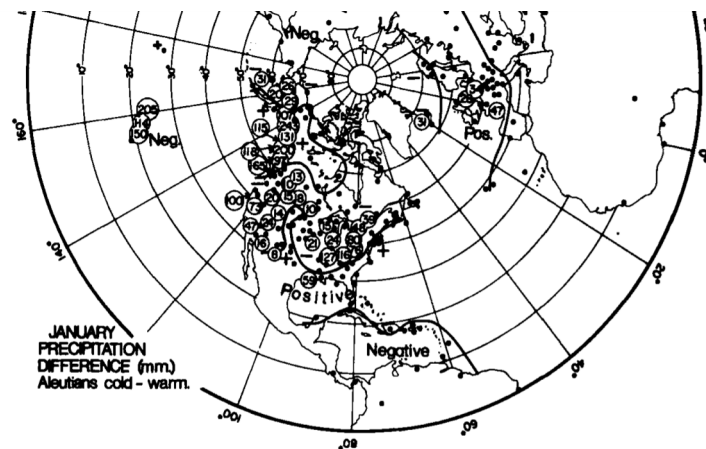


Figura 4.5: Diferencia en la precipitación media de Enero para AB menos AA de 1906 a 1980. (Rogers (1981))

El NPO está asociado con las anomalías regionales climáticas en temperatura y precipitación que ocurren en América del Norte (Figura 4.5). Los puntos indican posiciones de estaciones y los valores en círculo representa los totales de precipitaciones en estaciones donde la precipitación es estadísticamente significativa sobre un intervalo del 95% de confianza (Rogers (1981)), además su impacto es importante en la precipi-

4.2. Índices climáticos

tación invernal del Noroeste del Pacífico, el oeste de México y el sur-centro de las Grandes Planicies de E.U. (Linkin and Nigam (2008) ; Trenberth and Hurrell (1994))

4.2.2.1. Índice del Pacífico Norte (NPI)

El Índice del Pacífico Norte (NPI, en inglés) es definido para medir las variaciones decenales, se mide la presión media a nivel del mar sobre la región 30 a 65 N y 160 E to 140 W (Trenberth and Hurrell (1994))

4.2.3. Oscilación Decadal del Pacífico (PDO)

La Oscilación Decadal del Pacífico (PDO, en inglés) es un patrón de anomalías en la temperatura de la superficie del mar en el Norte del Pacífico con periodos de 20 a 30 años (Mantua et al. (1997)). Edwards (1997) El PDO tiene una fase positiva (figura 4.6a), cuando el agua superficial del lado americano es más cálida que el agua de las costas de Asia. Al mismo tiempo, el centro de presión baja Aleutiano en el Golfo de Alaska se fortalece, los cuales son mayor cantidad de tormentas en el Pacífico se mueven de Alaska a California. Al presentarse, los inviernos en la costa oeste norteamericana son más cálidos y secos. (Ahrens (2009))

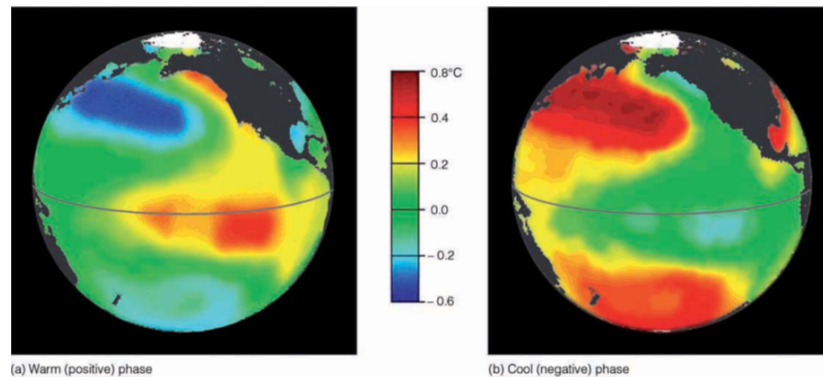


Figura 4.6: a) Fase cálida y b) Fase fría del PDO (Ahrens (2009))

La fase negativa (figura 4.6b) presenta la temperatura de agua superficial de Pacífico es más fría del lado americano que del lado asiático ocasionando inviernos más fríos y húmedos en la costa americana y más cálidos y secos en el sur de los Estados Unidos. (Ahrens (2009)) El PDO es muy útil para como herramienta de diagnóstico para la caracterización de la variabilidad a escala decenal del ENSO en gran parte porque es una integración del indicador interanual del ENSO con el patrón decenal de temperatura de la superficie del mar del Norte del Pacífico (PDO) (Newman et al. (2003)).

4.2.3.1. Índice de la Oscilación Decadal del Pacífico (PDO Index)

El PDO index es un conjunto de valores estandarizados derivados de las anomalías de temperatura superficial mensual (SST, en inglés) en el Océano Pacífico Norte, hacia

4.2. Índices climáticos

los polos de 20N para el periodo de 1900-1993 (Figura 4.7). Los cálculos se mantienen actualizados (NOAA-ESRL (2020)) La media de las anomalías mensuales de la SST media mundial es removida para separar este patrón de variabilidad de cualquier evidencia de calentamiento global"que puede estar presente en los datos.




Figura 4.7: Gráfica del PDO index de 1900 al 2017 (JISAO (2017))

4.2.4. Oscilación del Atlántico Norte (NAO)

El Golfo de México, al estar conectado con el Océano Atlántico, es afectado por la Oscilación del Atlántico Norte (NAO, por sus siglas en inglés), descrito por primera vez por Wallace and Gutzler (1981), siendo el sistema más importante de variación atmosférica sobre el Atlántico Norte e influye en el estado del tiempo y en el clima del este de Norteamérica y Eurasia (van Loon and Rogers (1978); Hurrell (1995); Kushnir (1999)). Está presente en todo el año, sin embargo, disminuye su influencia en las temporadas cálidas del año. Cuando disminuye la presión en el centro de baja presión en Islandia y aumenta en el centro de alta presión se denomina fase positiva (figura 4.8a) provocando en el este de Estados Unidos inviernos ligeros y húmedos mientras que en Canadá y Groenlandia son fríos y secos. La fase negativa del NAO ocurre cuando la presión atmosférica en el centro de baja presión de Islandia aumenta mientras que decrece el centro de alta presión de las Azores. Este cambio de presión disminuye los gradientes de presión y debilita los vientos que provienen de estos ocasionando inviernos ligeros para Canadá y Groenlandia e inviernos fríos y secos para el Este de Estados Unidos (figura 4.8b).

El CPC-NOAA (2004) indica que en condiciones de Niña en el Océano Pacífico tropical en conjunto con una muy negativa fase de la Oscilación del Atlántico Norte contribuye en el desarrollo de un patrón de circulación a escala planetaria que incluye uno fuerte,

4.2. Índices climáticos

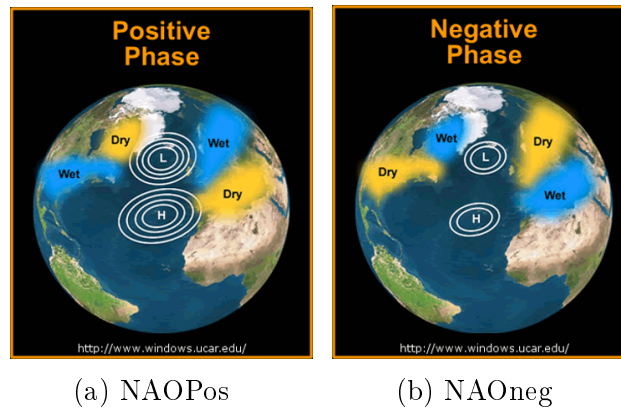


Figura 4.8: Fase positiva y b) Fase negativa del NAO durante el invierno Ahrens (2009)

de un alto nivel, con crestas, atravesando el suroeste de los Estados Unidos generando en la primavera de 1996 una sequía que afectó el Suroeste de los Estados Unidos y sus planicies en el Sur.

4.2.4.1. Índice mensual de la Oscilación del Atlántico Norte (NAO Index)

El índice mensual del NAO (NAO Index) es definido por el patrón de comportamiento del NAO definido como la principal modalidad del análisis de la Función Empírico de Giro Ortogonal (REOF, por sus siglas en inglés) de la media mensual de 500 mb durante el periodo de 1950-2000. (Figura 4.9) (NOAA (2020))

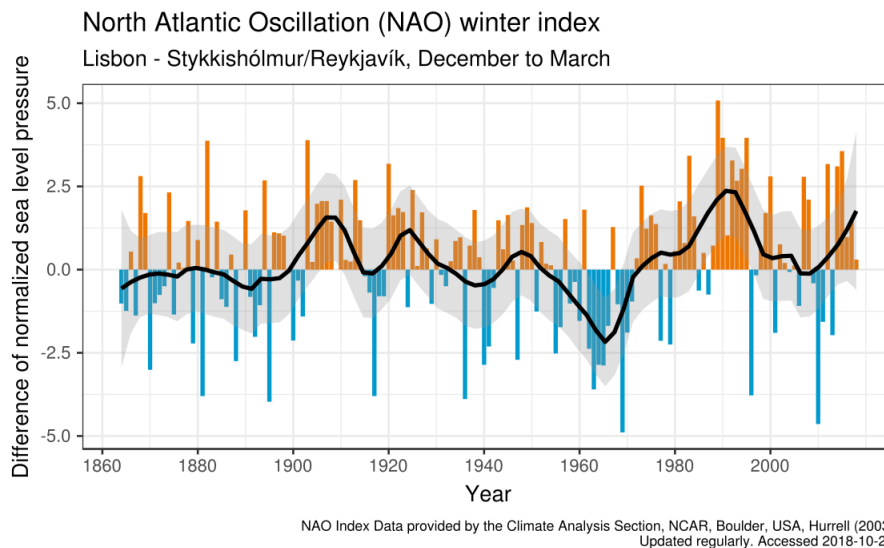


Figura 4.9: Gráfica del NAO index de 1900 al 2019 Hurrell et al. (2013)

4.2. Índices climáticos

4.2.5. La Oscilación Multidecenal del Atlántico (AMO)

Usando análisis de espectro singular en los registros de la temperatura global desde 1850, [Schlesinger and Ramankutty \(1994\)](#) identificaron una oscilación en la temperatura del Atlántico en periodos de tiempo aproximados de 65 a 70 años. [Delworth and Mann \(2000\)](#) demostraron que tanto en el modelo como en las observaciones, la TSM parece transmitir la señal multidecadal y que la evolución del modelo implica fluctuaciones en la intensidad de la circulación termohalina del Atlántico. (Figura 4.10)

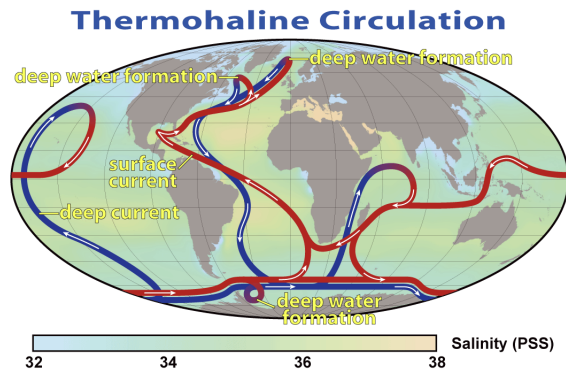


Figura 4.10: Patrón de circulación termohalina del Atlántico [Simmon \(2008\)](#)

El Índice de la Oscilación Multidecenal del Atlántico (AMO index) es un índice de la variabilidad decadal en el Atlántico basado en la temperatura de la superficie del mar, al ser construido de allí, que responde al forzamiento atmosférico rápidamente, la serie de tiempo AMO está dominada por variaciones de baja frecuencia (múltiples décadas) (Figura 4.11)

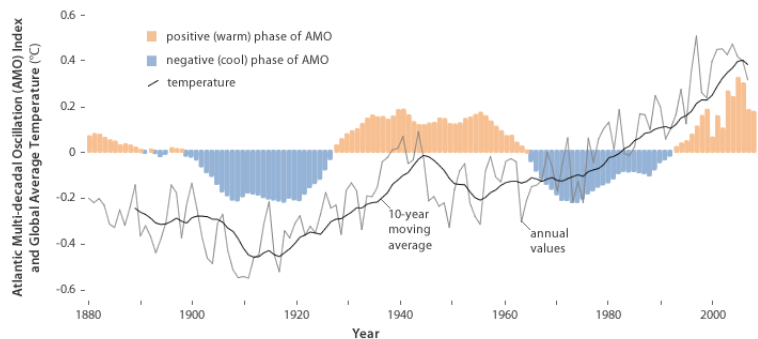


Figura 4.11: Temperatura media global entre 1880-2009 en comparación con el índice de oscilación atlántica multidecadal (AMO) [Trenberth \(2019\)](#)

4.2. Índices climáticos

4.2.6. Sistema Aleutiano de Baja Presión atmosférica

El Sistema Aleutiano de Baja Presión atmosférica (ALP, en inglés) es una característica semipermanente del Pacífico Norte, generalmente centrado sobre las Islas Aleutianas. (Surry and King (2015)). Este sistema se fortalece en invierno y en verano se debilita, aunque la intensidad del fenómeno varía año con año, afectando la intensidad de las tormentas invernales (Bromirski et al. (2003)) y la dirección de la circulación atmosférica frente a la costa oeste de Norteamérica.(McFarlane et al. (2000))

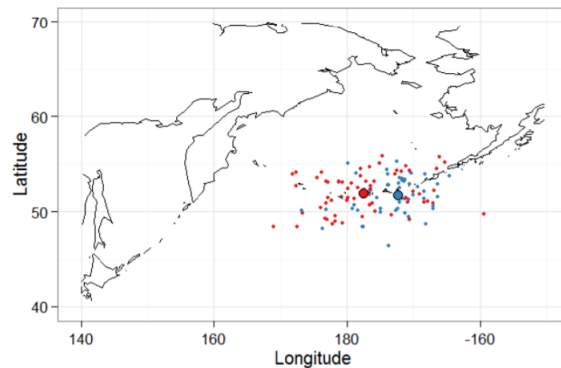


Figura 4.12: Locaciones geográficas del centro de ALP de 1900-2015 (Surry and King (2015))

En la figura 4.12 se muestra en rojo y en azul los centros de una presión baja débil y una presión baja intensa en las Islas Aleutianas respectivamente. Los círculos más grandes son los valores más extremos de cada nivel de intensidad de presión.(Surry and King (2015)) Cuando la Presión baja Aleutiana está dirigida hacia el norte y es débil resulta en una corriente de viento con dirección poniente sobre el Pacífico Norte. Si es fuerte y esta dirigida al sur, el resultado son los vientos del sudoeste en la costa Norteamericana. La intensidad del invierno en las Islas Aleutianas está vinculado en los patrones de productividad marina.(Beamish and Bouillon (1993); McFarlane et al. (2000); King et al. (2001)).

El Índice de Sistema de Baja Presión de las Aleutianas (ALPI, en inglés) es definido como una anomalía del área media estacional del área media estacional a largo plazo (1950 - 1997) el área estacional media (diciembre - marzo; asignada al año de enero; (km²)) en el Pacífico norte con una presión a nivel del mar menor o igual a 100.5 kPa. (Figura 4.13)

4.3. Generalidades del Altiplano Mexicano




Figura 4.13: Índice de Sistema de Baja Presión de las Aleutianas (ALPI) [Surry and King \(2015\)](#)

4.3. Generalidades del Altiplano Mexicano

La región tiene un área de 601,511.05 kilómetros cuadrados (figura 4.14), que representa el 30.49% del territorio nacional y esta delimitada al poniente por la Sierra Madre Occidental, al sur por el Eje Neovolcánico Transversal, el oriente por la Sierra Madre Oriental y al norte por la frontera de México con los Estados Unidos, dentro de la misma región hay varias cadenas montañosas pequeñas entre las más importantes están sierra de Zacatecas, la sierra de la Breña, la sierra de San Luis y la sierra de Guanajuato ([INEGI. \(2008\)](#)). Las provincias fisiográficas que la conforman son Sierras y llanuras del Norte, Grandes llanuras de Norteamérica, Sierra Madre Occidental, Sierra Madre Oriental, Llanura Costera del Golfo Norte y Mesa del Centro ([INEGI. \(2001\)](#)). (Figura 4.15)



Figura 4.14: Ubicación de la región del Altiplano Mexicano *Elaboración propia*

4.3. Generalidades del Altiplano Mexicano

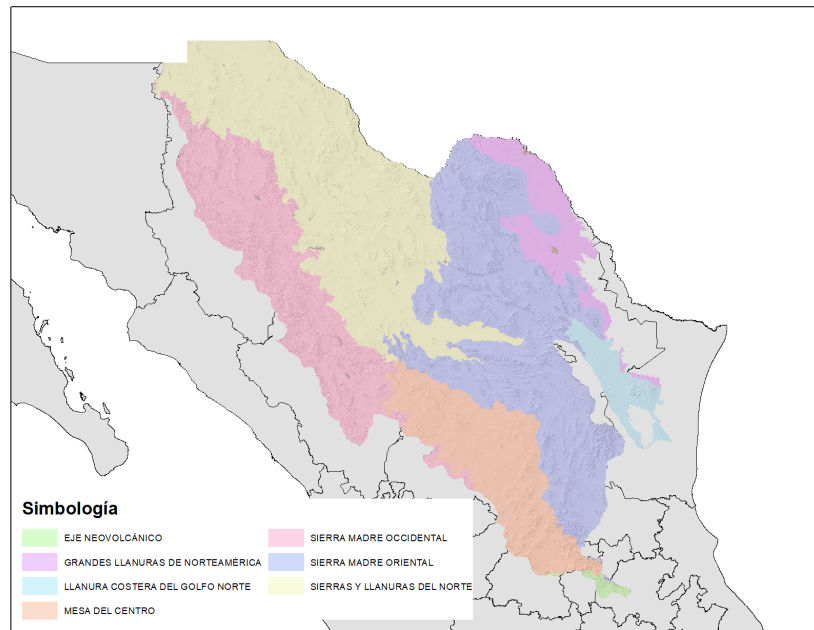


Figura 4.15: Provincias fisiográficas del Altiplano Mexicano (INEGI. (2001))

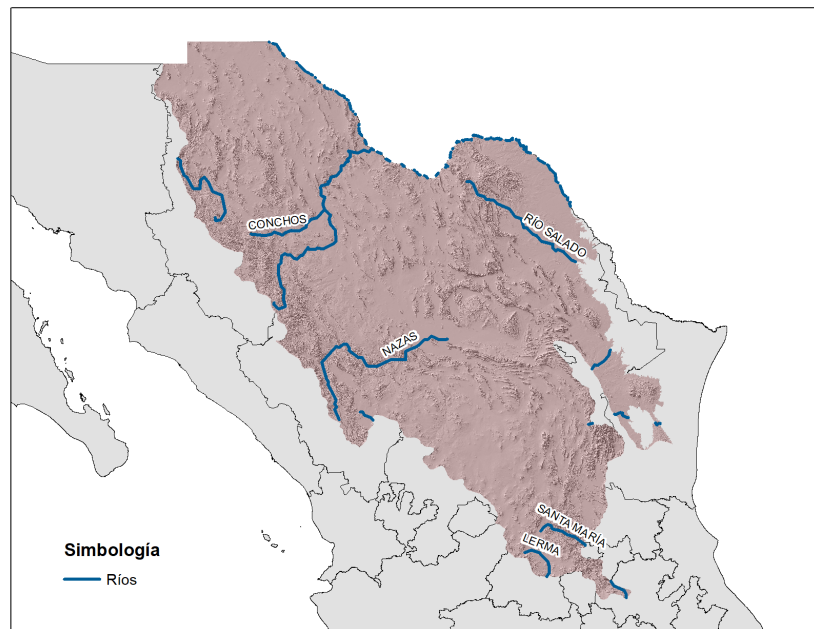


Figura 4.16: Principales ríos del Altiplano Mexicano (INEGI. (2008))

Entre los ríos más importantes en la región están los ríos Conchos y Río Salado que forman parte de la cuenca del Río Bravo/Grande, al norte y poniente, el Río Papagochic, que forma parte de la cuenca del Yaqui, y el Río Nazas al poniente, los ríos

4.4. Cultivo del frijol (*Phaseolus vulgaris L.*)

Lerma-Santiago, Santa María y Moctezuma-Pánuco al sur, por último, el Río Pílon de San Juan y el Río San Fernando al oriente. (INEGI. (2008)) (Figura 4.16)

Los climas que presenta la región es muy variada como se muestra en la tabla 4.1. Cabe mencionar que los climas secos representan el 61.65 % del territorio, los climas semisecos representan el 12.27 % y el 26.08 % son subhúmedos. (INEGI (2008))

Cuadro 4.1: Climas del área de estudio, su área en Ha. y el porcentaje del área total (INEGI (2008))

Clima	Área (Ha.)	% Total
Cálido subhúmedo	11,708.18	0.02 %
Muy seco cálido	34,911.20	0.06 %
Muy seco semicálido	13'221,690.65	21.98 %
Muy seco templado	6'436,134.35	10.70 %
Seco cálido	1'272,577.44	2.12 %
Seco semicálido	8'972,359.48	14.92 %
Seco templado	7'142,595.03	11.87 %
Semicálido subhúmedo	430,109.64	0.72 %
Semifrío subhúmedo	2'576,209.44	4.28 %
Semiseco cálido	584,272.48	0.97 %
Semiseco semicálido	2'098,588.10	3.49 %
Semiseco semifrío	162,183.97	0.27 %
Semiseco templado	12'672,677.65	21.07 %
Templado subhúmedo	4'535,087.83	7.54 %
Total general	60'151,105.44	100.00 %

4.4. Cultivo del frijol (*Phaseolus vulgaris L.*)

4.4.1. Generalidades

El cultivo del frijol no crece en climas tropicales, húmedos y con poca altitud. El rango de temperaturas común es de 18° a 30° C, sin embargo, el óptimo es de 15° a 20° C. La temperatura de germinación debe ser mayor de 15° C. El cultivo es sensible a temperaturas mayores de 30° C, en especial en la floración y las semillas, y al frío, las flores son dañadas a los 5° C. Los vientos fuertes pueden dañar el cultivo y si son los vientos muy secos afectan la polinización y, por ende, el rendimiento. (Sys et al. (1993))

Puede ser crece en suelos con texturas arenos arcillosas a arcillas. La profundidad mínima es de 0.5 m aunque el óptimo es mayor de 0.75 m. El drenaje es muy importante en este cultivo, la más mínima anegación, en unas horas, lo daña. El rango de pH es de 5.2 - 8.2, con un óptimo de 6.0 - 7.0. No hay reducción de rendimiento ante una conductividad eléctrica de menos de 1 dS/m; se reduce en 10 % con 1.5; 25 % con 2.3; 50 % con 3.6 y 100 % con 6.5 dS/m. (Sys et al. (1993))

CAPÍTULO 5

MODELACION ESTADISTICA:FUNDAMENTOS TEÓRICOS

5.1. Modelos probabilísticos para la precipitación

5.1.1. Distribución Gamma

[Thom \(1951\)](#)) sugirió la distribución de dos parámetros Gamma (G2) para modelar la forma de la distribución de la intensidad de precipitación promedio medida en el tiempo (promedios diarios). [Buishand \(1978\)](#) utiliza y el modelo Gama en series de precipitación diaria de seis estaciones, observando que su coeficiente de asimetría y el coeficiente de variación empírico se parece al de una distribución Gamma:

$$f(x) = \frac{x^{\alpha-1} e^{(-\frac{x}{\beta})}}{\beta^{\alpha} \Gamma(\alpha)} \quad x \geq 0; \alpha, \beta > 0 \quad (5.1)$$

Para la precipitación diaria, el parámetro α de forma controla la probabilidad de precipitación diaria ligera y moderada totales, mientras que el parámetro de escala β es una medida útil para estudiar el comportamiento de los extremos.

Los estimadores de máxima verosimilitud de los parámetros fueron publicadas posteriormente ([Thom \(1966\)](#)) y corresponden a:

$$\hat{\alpha} = \frac{1}{A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (5.2)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (5.3)$$

5.1. Modelos probabilísticos para la precipitación

Dónde:

$$\begin{aligned} A &= \ln(\bar{x}) - \frac{\sum \ln(x)}{n} \\ n &= \text{obs. precipitación} \\ x &= \# \text{ datos de precipitación} \end{aligned}$$

Usando estos parámetros estimados (5.2 y 5.3) junto con la función acumulativa de probabilidades de la distribución Gamma es posible obtener una estimación de la probabilidad acumulada de una precipitación observada, que es dado por:

$$G(x) = \int_0^x g(x)dx = \frac{1}{\widehat{\beta}^{\widehat{\alpha}}\Gamma(\widehat{\alpha})} \int_0^x x^{\widehat{\alpha}-1} e^{-x/\widehat{\beta}} dx \quad (5.4)$$

Ya que puede no llover, la precipitación puede ser 0, como la distribución gamma (5.4) no toma valor cuando $x = 0$, ya que no forma parte de su soporte, Thom (1966) modificó la función de distribución de la siguiente manera:

$$H(x) = q + (1 - q)G(x) = q + (1 - q) \frac{1}{\widehat{\beta}^{\widehat{\alpha}}\Gamma(\widehat{\alpha})} \int_0^x x^{\widehat{\alpha}-1} e^{-x/\widehat{\beta}} dx \quad (5.5)$$

Dónde: q es probabilidad de observar ceros, y puede ser estimada por $\hat{q} = m/n$ con m =número de ceros y n =observaciones de precipitación.

5.1.2. Distribución Gamma Generalizada

Algunos autores con Martínez-Villalobos and Neelin (2019) analizan el uso del modelo Gama para modelar precipitación en diferentes condiciones climáticas y de bajo cambio climático y sugieren adecuaciones al modelo original.

Si bien la distribución Gamma con dos parámetros es, con mucho, la distribución preferida para modelar precipitaciones pluviales en días húmedos, se han sugerido otras distribuciones. Woolhiser and Roldan (1982) y Wilks (1998) sugieren el uso de una distribución exponencial mixta de tres parámetros en lugar de la Gamma. A través de una variedad de pruebas de bondad de ajuste y análisis de probabilidad logarítmica, Wilks muestra que la exponencial mixta es la preferida a la Gamma. El weibull (W2) y, en menor medida, la distribución exponencial también se ha sugerido para modelar las cantidades diarias de lluvia (Duan et al. (1995); Burgueno et al. (2005)). Estas distribuciones forman parte de la familia de la Gamma Generalizada, ya son casos especiales de la misma (Stacy (1962)). Además, Sharma and Singh (2010) comenta que las distribuciones que ajustan difieren mucho de mes a mes. La función

5.1. Modelos probabilísticos para la precipitación

de densidad para la Gamma Generalizada propuesta por Stacy (1962) es:

$$GG(x; a, d, p) = \frac{p}{a^d} x^{d-1} \frac{\exp\left\{\left(\frac{-x}{a}\right)^p\right\}}{\Gamma\left(\frac{d}{p}\right)} \quad (5.6)$$

para valores no negativos de x y $a > 0; d > 0; p > 0$.

Lagos et al. (2011) utilizan el modelo Gamma Generalizado y estudian algunas re-parametrizaciones y comparan diferentes tipos de estimadores aplicando el modelo a datos de precipitación.

5.1.3. Distribución Beta Generalizada tipo II

La Distribución Beta Generalizada fue introducida por McDonald (1984). Una variable aleatoria Y se dice que sigue una distribución Beta Generalizada (GB) si tiene una función de densidad:

$$GB(y; a, b, c, p, q) = \frac{|a|y^{ap-1}(1 - (1 - c)(y/b)^a)^{q-1}}{b^{ap}B(p, q)(1 + c(y/b)^a)^{p+q}} \quad \text{para } 0 < y^a < \frac{b^a}{1 - c}. \quad (5.7)$$

con $0 \leq c \leq 1$ y b, p, y y q positivos. La función $B(p, q)$ es la función beta.

La Beta Generalizada del tipo I (GB1) y tipo II (GB2) son sub modelos de la GB y son definidas respectivamente por:

$$GB1(y; a, b, p, q) = \frac{|a|y^{ap-1}(1 - (y/b)^a)^{q-1}}{b^{ap}B(p, q)}, \quad 0 < y^a < b^a \quad (5.8)$$

$$GB2(y; a, b, p, q) = \frac{|a|y^{ap-1}}{b^{ap}B(p, q)(1 + (y/b)^a)^{p+q}}, \quad y \geq 0. \quad (5.9)$$

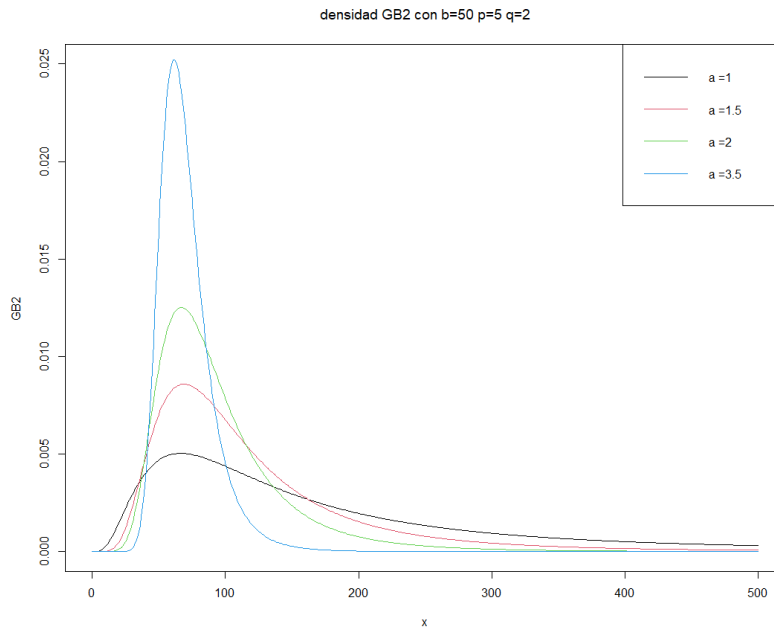
Dónde: $b > 0; p > 0; q > 0$

La distribución GB2 ha sido ampliamente utilizada para modelar la variable de ingreso en estudios de desigualdad en distribución de la riqueza.

Chen and Singh (2017) utilizan el modelo GB2 para modelar y estimar la magnitud de las inundaciones para un intervalo de recurrencia dado, encontrando que el ajuste de la distribución GB2 es mejor que el de otras distribuciones ampliamente utilizadas en hidrología (figura 5.2).

Mielke Jr. and Johnson (1974) considera que la distribución Beta Generalizada tipo II, es una buena distribución para cuestiones hidrológicas y en meteorología. Además, las distribuciones que forman parte de la Gamma Generalizada (subsección 5.1.2) forman parte de la familia de la Beta Generalizada tipo II (GB2)(Figura 5.1).

5.1. Modelos probabilísticos para la precipitación



H

Figura 5.1: Gráfica de densidad de la GB2 con parámetros $a=(1, 1.5, 2, 3.5)$, $b = 50, p = 5, q = 2$

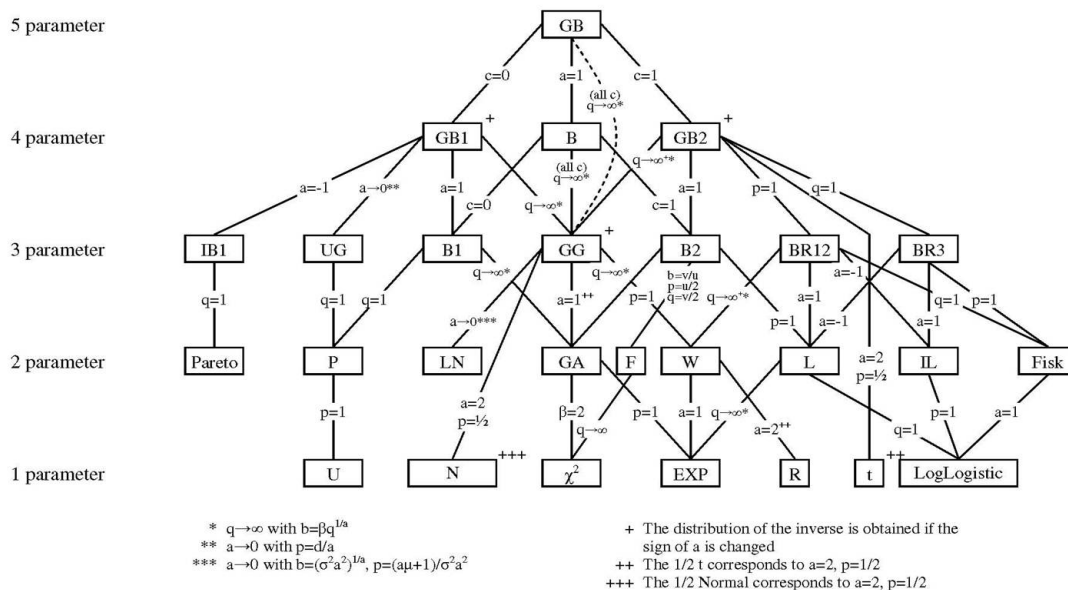


Figura 5.2: Familia de distribución Beta Generalizada (GB) (McDonald (2008))

La caracterización de ls GB2 y algunos resultados son dados por McDonald (2008).

5.1. Modelos probabilísticos para la precipitación

la función de distribución acumulativa de la GB2 es:

$$F(y) = B\left(\frac{(y/b)^a}{1 + (y/b)^a}; p, q\right) \quad (5.10)$$

La distribución del k ésimo momento de la GB2:

$$GB2\left(a, p + \frac{k}{a}, q - \frac{k}{a}\right) \quad (5.11)$$

Los k -momentos para la distribución GB2 son dados por:

$$E(Y^k) = \frac{b^k B(p + \frac{k}{a}, q - \frac{k}{a})}{B(p, q)}, \quad q > k/a \quad (5.12)$$

La distribución GB2 (eq. 5.9) anida una cantidad importante de distribuciones como casos especiales o casos límite, incluyendo la distribución Gamma Generalizada (GG), la Burr tipo 3 y 12, la distribuciones lognormal (LN), Weibull (W), gamma (GA), Lomax (L), F , Rayleigh (R), chi cuadrada (χ^2), mitad de normal ($\frac{1}{2} N(0, \sigma^2)$), mitad de Student t ($\frac{1}{2} t$), exponencial (EXP) y log-logística. (McDonald (2008))

5.1.4. Distribuciones de Valores Extremos

Ya que se busca predecir la sequía, y este es un evento extremo de la precipitación, también se estudió las distribuciones de valores extremos (GEV), como lo sugiere Jenkinson (1955), Stagge et al. (2015) y Ferrari and Ozaki (2014). Las Distribuciones de Valores Extremos se basan en la Teoría del Valor Extremo y permite modelar eventos que ocurren con poca probabilidad, es una herramienta poderosa y útil para describir situaciones atípicas que pueden tener un impacto significativo, tal como lo es el fenómeno de la sequía.

5.1.4.1. Teoría del Valor Extremo

Muchos métodos estadísticos (regresión, etc.) están diseñados para modelar el comportamiento de los promedios de variables aleatorias. En muchos casos, sin embargo, los valores extremos en los datos son de mayor interés. Por ejemplo, si estamos estudiando el comportamiento de la precipitación pluvial en el tiempo, los valores que están demasiado altos, podrían indicar riesgos de inundación y si están demasiado bajos, entonces se podrían presentar sequías. Un valor extremo de algunas variables aleatorias suele ser su máximo o su mínimo. En este trabajo, se habla del máximo. De forma análoga, también podríamos obtener los mismos resultados para su mínimo.

5.1.4.2. Distribución del máximo

Para inferir sobre valores extremos, es conveniente analizar la distribución del máximo de una la muestra aleatoria. El extremo es en si una variable aleatoria. La Teoría del

5.1. Modelos probabilísticos para la precipitación

Valor Extremo explica el comportamiento estadístico del máximo(mínimo) de un conjunto de variables aleatorias independientes (X_1, \dots, X_n) que tienen una distribución común F .

$$M_n = \max X_1, \dots, X_n,$$

Normalmente X_i representa valores tomados de procesos medidos a escala regular, por ejemplo, temperaturas diarias o nivel de altura de un río, tal que M_n es el máximo del proceso en n unidades de tiempo de observación. (Coles et al. (2001))

Cuando $n \rightarrow \infty$ el comportamiento de M_n tiende a degenerarse en una constante. Para obtener una distribución no degenerada, se realiza una normalización de la variable M_n .

$$M_n^* = \frac{M_n - \mu_n}{a_n}$$

Dónde: $a_n > 0$ y b_n estabilizan la escala y localidad de M_n cuando $n \rightarrow \infty$.

Si existe una secuencia de constantes $\mu_n > 0$ y σ_n tal que

$$Pr(M_n - \mu_n) / \sigma_n \leq z \rightarrow G(z)$$

cuando $n \rightarrow \infty$ donde G es una función de distribución no degenerada, entonces G pertenece a alguna de las siguientes familias:

$$\begin{aligned} a) G_I(z) &= \exp \left\{ -\exp \left[- \left(\frac{z - \mu}{\sigma} \right) \right] \right\}, \quad -\infty < z < \infty \\ b) G_{II}(z) &= \begin{cases} 0, & z \leq \mu \\ \exp \left\{ - \left(\frac{z - \mu}{\sigma} \right)^{-\alpha} \right\}, & z > \mu \end{cases} \\ c) G_{III}(z) &= \begin{cases} 1, & z \geq \mu \\ \exp \left\{ - \left[- \left(\frac{z - \mu}{\sigma} \right)^\alpha \right] \right\}, & z < \mu \end{cases} \end{aligned} \quad (5.13)$$

Para los parámetros $\mu > 0$, σ y, para las familias eq. 5.13b y eq. 5.13c, $\alpha > 0$. Las distribuciones eq. 5.13a, eq. 5.13b y eq. 5.13c son conocidas como las familias de distribuciones Gumbel, Fréchet y Weibull, respectivamente. Donde σ y μ , fungen como parámetros de escala y localidad. Para las familias eq. 5.13b y eq. 5.13c tienen además el parámetro de forma α .

Las familias de distribuciones eq. 5.13a, eq. 5.13b y eq. 5.13c forman parte de una sola familia de distribuciones, conocida como la familia de Distribuciones de Valores Extremos Generalizada, cuya función de distribución es:

$$G(z) = \exp \left\{ - \left[1 + \alpha \left(\frac{z - \mu}{\sigma} \right) \right]^{-\frac{1}{\alpha}} \right\}, \quad \begin{matrix} 1 + \alpha \left(\frac{z - \mu}{\sigma} \right) > 0 \\ -\infty < \alpha < \infty, \sigma > 0 \end{matrix} \quad (5.14)$$

5.2. Modelos estadísticos en datos de precipitación

La distribución de Valores Extremos Generalizada (GEV) 5.14 puede tomar las formas 5.13b y 5.13c, cuando $\alpha > 0$ y $\alpha < 0$, respectivamente. En cambio si $\alpha \rightarrow 0$, GEV (eq. 5.14) toma la forma 5.13a. (Coles et al. (2001))

5.2. Modelos estadísticos en datos de precipitación

Para investigar las relaciones entre la precipitación pluvial con algunas covariables de interés se pueden utilizar algunos modelos que tradicionalmente se emplean en investigación con el fin de describir las relaciones de una variable respuesta Y con predictores X_1, \dots, X_n , para hacer inferencia del modelo y predecir Y por medio de conjuntos de valores de X_1, \dots, X_n . Los modelos lineales tienen la ventaja de ser simples para lograr dicha tarea, suma la contribución de las predicciones de cada variable y da un método simple para obtener las predicciones. Si se generaliza se puede ver como la siguiente función:

$$Y = f(X_1, \dots, X_n) + \epsilon \quad (5.15)$$

A continuación se presenta una breve descripción de modelos alternativos al modelo lineal clásico.

5.2.1. Modelos Lineales Generalizados (GLM)

Los modelos lineales generalizados (GLM) proporcionan una mayor flexibilidad en el análisis de datos relacionados con distribuciones no normales. Los modelos Lineales Generalizados GLM (Generalized Linear Models, en inglés), extienden los modelos de regresión lineales estándar (5.15) para abarcar las distribuciones respuesta que pertenecen a la familia exponencial y posiblemente funciones no lineales de la media. (Agresti (2015))

$$g[E(y)] = \mathbf{X}\underline{\beta} \quad (5.16)$$

Eq. 5.16 tiene tres componentes:

- El componente aleatorio $[E(y)]$:

Especifica la variable de respuesta Y y su probabilidad distribución en la familia exponencial. Las observaciones $Y = (y_1, \dots, y_n)^T$ en esa distribución son tratadas como independientes.

- El predictor lineal $[\mathbf{X}\underline{\beta}]$:

Para un vector de parámetros $\underline{\beta} = (\beta_1, \beta_2, \dots, \beta_p)^T$ y una matriz de modelo \mathbf{X} ($n \times p$) que contiene valores de p variables explicativas para las n observaciones, el predictor lineal es $\mathbf{X}\underline{\beta}$. También es conocido como *componente sistémico*. Tiene n filas, una por cada observación, y p columnas, una por cada parámetro en $\underline{\beta}$. En la práctica, usualmente $p \leq n$, la meta de la parsimonia es resumir los datos utilizando un número menor de parámetros, además que apesar de ser teóricamente fijo, en algunas ocasiones, x_i puede ser aleatorio.

5.2. Modelos estadísticos en datos de precipitación

- La función liga $[g()]$:

La función liga tiene como propósito relacionar el componente aleatorio con el predictor lineal. Sea $\mu_i = E(y_i), i = 1, \dots, n$. El GLM vincula ν_i a μ_i por $\nu_i = g(\mu_i)$, donde la función de enlace $g()$ es una función monotóna y diferenciable. Así, g vincula μ_i a variables explicativas a través de la fórmula:

$$g(\mu_i) = \sum_{j=1}^p \beta_j x_{ij}, i = (1, \dots, n)$$

Cada distribución de probabilidad potencial para Y tiene una función especial de la media que se llama su *parámetro natural*. La función de enlace g que transforma μ_i en el parámetro natural se llama enlace canónico. Aunque son posibles otras funciones de enlace, en la práctica los enlaces canónicos son los más comunes. (Agresti (2015))

5.2.2. Modelos aditivos

El modelo aditivos según lo propuesto por Hastie and Tibshirani (1990), tiene un predictor lineal que interactúa con una suma de funciones suaves de covariables. El modelo aditivo proporciona una estructura para generalizar un modelo lineal general al permitir la aditividad de funciones no lineales de las variables.

Los modelos aditivos conservan algunas características en del modelo lineal, *son aditivos en los efectos predictores y se puede examinar los efectos de predictores por separado, en ausencia de interacciones.*

Un modelo aditivo es definido como (Hastie and Tibshirani (1990)):

$$Y = \alpha + \sum_{j=1}^p f_j(X_j) + \epsilon \quad (5.17)$$

Donde α es el intercepto, los f_j son funciones suavizadas y univariadas para cada predictor, los errores son independientes de las X_j , de distribución $N(0, \sigma^2)$. (Wood (2006)). Normalmente se muestra a las f_j como univariadas y suaves, sin embargo, esas propiedades no son necesarias. (Hastie and Tibshirani (1990))

Otra característica que conserva del modelo lineal (5.15) es *la variación de la superficie de respuesta ajustada que mantiene todos los predictores pero un predictor fijo no depende de los valores de los otros predictores*, aunque se paga ya que el modelo aditivo es siempre una *aproximación de la verdadera superficie de regresión* (Hastie and Tibshirani (1990)).

Las funciones estimadas desde un modelo aditivo son análogos a los coeficientes en la regresión lineal. Todos los trucos encontrados en la interpretación de los modelos de la regresión lineal aplican en los modelos aditivos. Hay que tener cuidado de no interpretar funciones para variables que son insignificantes, y que no afecten a las importantes. Una estrategia es seleccionar y eliminar las variables de manera gradual (stepwise) (Hastie and Tibshirani (1990)).

5.2. Modelos estadísticos en datos de precipitación

5.2.2.1. Estimación de ecuaciones para los modelos aditivos

El modelo aditivo $E(Y|X) = \sum_{j=1}^p f_j(X_j)$ puede ser estimado por medio de un algoritmo llamado *backfitting* (5.2.1) (Hastie and Tibshirani (1990)). el cual consta de:

Algoritmo 5.2.1: El Algoritmo backfitting.

- (i) Inicializa: $f_j = f_j^{(0)}, j = 1, \dots, p$
- (ii) Repetir $j = 1, \dots, p; 1, \dots, p; \dots$

$$f_j = S_j(y - \sum_{k \neq j} f_k | x_j)$$

- (iii) Continúa (ii) hasta que las funciones individuales no cambien

En lo anterior, los f_j son los n-vectores $(f_j(x_{1j}), \dots, f_j(x_{nj}))^T$, con x_{ij} en el orden de y_i . Se omite la constante α , sin embargo, no cambia los resultados de los estimados. (Hastie and Tibshirani (1990))

5.2.2.2. Regresión por partes penalizada como representación de un modelo aditivo

Cada función (f_j) puede ser representada usando una base lineal por partes penalizada (Hastie and Tibshirani (1990)). Sea:

$$f_j(x_i) = \sum_{m=1}^{k_j} b_{jm}(x_{ji}) \delta_j; j = 1, \dots, p; i = 1, \dots, n$$

donde δ_m son los coeficientes desconocidos, mientras los $b_{jm}(x)$ son las funciones básicas de las funciones lineales por partes mencionado en el apartado 5.2.1, usando una secuencia de k_j nudos, espaciados uniformemente en el rango de x_j .

Definiendo un vector $\mathbf{f}_j = [f_j(x_i)]^T; i = 1, \dots, n$ se tiene que $\mathbf{f}_j = \mathbf{X}_j \delta_j$ donde $b_m(x_i)$ es el elemento i, m de \mathbf{X}_j . Una penalidad, como en el apartado 5.2.2 es asociada con cada función: $\delta_j^T \mathbf{D}_j^T \mathbf{D}_j \delta_j = \delta_j^T \tilde{\mathbf{S}}_j \delta_j$ para f_j .

Las mejores restricciones son las restricciones de suma a cero como:

$$\sum_{i=1}^n f_j(x_i) = 0 \quad o \quad \underline{1}^T \mathbf{f}_j = 0 \quad (5.18)$$

donde $j = 1, \dots, p$ y $\underline{1}$ es un vector de 1 con n elementos. Note que esta restricción permite mantener a f_j su misma forma antes de la restricción, con el mismo valor de penalización. Aunque el único efecto es cambiar f_j , verticalmente, de modo que su valor medio sea cero.

Así, aplicando la restricción, note que $\underline{1}^T \mathbf{X}_j \delta_j = 0$ para todo $\delta_j \rightarrow \underline{1}^T \mathbf{X}_j = 0$. Para conseguir esta condición la media de la columna se puede restar de cada columna de X_j . Es decir, definimos una matriz centrada en columna $\tilde{\mathbf{X}}_j = \mathbf{X}_j - \underline{1} \underline{1}^T \mathbf{X}_j / n$ y establecemos $\tilde{f}_j = \tilde{\mathbf{X}}_j \delta_j$. Es fácil comprobar que esta restricción no impone más que

5.2. Modelos estadísticos en datos de precipitación

un cambio en el nivel de \mathbf{f}_j :

$$\begin{aligned}\tilde{f}_j &= \tilde{\mathbf{X}}_j \delta_j \\ &= \mathbf{X}_j \delta_j - \underline{\mathbf{1}} \mathbf{1}^T \mathbf{X}_j \delta_j / n \\ &= \mathbf{X}_j \delta_j - 1c \\ &= \mathbf{f}_j - c\end{aligned}$$

Donde el escalar $c = \underline{\mathbf{1}}^T \mathbf{X}_j \delta_j / n$, una vez establecida la base de la restricción para f_j es sencillo volver a expresar como:

$$\underline{y} = \mathbf{X} \underline{\beta} + \underline{\epsilon}$$

donde $\mathbf{X} = (1, \mathbf{X}_1, \dots, \mathbf{X}_p)$ y $\underline{\beta}^T = (\underline{\alpha}, \underline{\delta}_1^T, \dots, \underline{\delta}_p^T)$

Apartado 5.2.1: Funciones lineales por partes (Hastie and Tibshirani (1990)).

$$b_j(x) = \begin{cases} (x - x_{j-1}) / (x_j - x_{j-1}); & x_{j-1} < x \leq x_j \\ (x_{i+j} - x) / (x_{j+1} - x_j); & x_j < x < x_{j+1} \\ 0; & \text{de otro modo} \end{cases}$$

donde $x_j, j = 1, \dots, k$ son los "nudos" son las ubicaciones en las que se unen las partes de las funciones lineales y se supone que $x_j > x_{j-1}$ para $j = 2, \dots, k - 1$.

Apartado 5.2.2: Controlar la suavidad penalizando la ondulación

Para las funciones triangulares, es fácil ver que los coeficientes de f son simplemente los valores de la función en los nudos, es decir, $\beta_j = f(x_j)$. Se puede expresar de forma sencilla la penalización como una forma cuadrática, $\underline{\beta}^T \mathbf{S} \underline{\beta}$, en los coeficientes básicos. La penalización se convierte en:

$$\sum_{j=2}^{k-1} (\beta_{j-1} - 2\beta_j + \beta_{j+1})^2 = \underline{\beta}^T \mathbf{D}^T \mathbf{D} \underline{\beta} = \underline{\beta}^T \mathbf{S} \underline{\beta}$$

donde $\mathbf{S} = \mathbf{D}^T \mathbf{D}$ (\mathbf{S} es obviamente un rango deficiente por la dimensión de la penalización espacio nulo).

5.2.2.3. Ajuste del modelo aditivo por mínimos cuadrados penalizados

Para estimar los coeficientes $\hat{\underline{\beta}}$ son obtenidos por la minimalización del objetivo de mínimos cuadrados penalizados (Hastie and Tibshirani (1990)).:

5.2. Modelos estadísticos en datos de precipitación

$$\|y - \mathbf{X}\underline{\beta}\|^2 + \lambda_1 \underline{\beta}^T \mathbf{S}_1 \underline{\beta} + \dots + \lambda_p \underline{\beta}^T \mathbf{S}_p \underline{\beta}$$

donde los parámetros suavizadores $(\lambda_1, \dots, \lambda_p)$ controlan el peso que se le dará al objetivo para hacer a $f_j, j = (1, \dots, p)$ suave, en relación con el objetivo de ajustarse estrechamente al datos de respuesta. Por el momento, suponga que se dan estos parámetros de suavizado. De manera similar al caso suavizado simple que tenemos:

$$\hat{\underline{\beta}} = (\mathbf{X}^T \mathbf{X} + \lambda_1 \mathbf{S}_1 + \lambda_2 \mathbf{S}_2)^{-1} \mathbf{X}^T y \quad \mathbf{A} = \mathbf{X}(\mathbf{X}^T \mathbf{X} + \lambda_1 \mathbf{S}_1 + \lambda_2 \mathbf{S}_2)^{-1} \mathbf{X}^T$$

pero esta expresión es poco óptima con respecto a la estabilidad computacional y es mejor reescribirla así:

$$\|y - \mathbf{X}\underline{\beta}\|^2 + \lambda_1 \underline{\beta}^T \mathbf{S}_1 \underline{\beta} + \lambda_2 \underline{\beta}^T \mathbf{S}_2 \underline{\beta} = \left\| \begin{bmatrix} y \\ \mathbf{0} \end{bmatrix} - \begin{bmatrix} \mathbf{X} \\ \mathbf{B} \end{bmatrix} \underline{\beta} \right\|^2$$

donde \mathbf{B} es una matriz tal que $\mathbf{B}^T \mathbf{B} = \lambda_1 \mathbf{S}_1 + \lambda_2 \mathbf{S}_2$.

5.2.2.4. Modelos aditivos generalizados (GAM)

Los modelos aditivos generalizados (GAM) se derivan de los modelos aditivos, ([Wood \(2006\)](#)) es decir el predictor lineal ahora predice alguna función suavizada monótona conocida del valor esperado de la respuesta, y dicha respuesta debe seguir una distribución de la familia exponencial o tener una relación conocida en relación de varianza media. El modelo resultante tiene como forma general:

$$g(\mu_i) = A_i \theta + f_1(x_{1i}) + f_2(x_{2i}) + f_3(x_{3i}, x_{4i}) + \dots \quad (5.19)$$

donde $\mu_i = E(Y_i)$ y $Y_i \sim EF(\mu_i, \phi)$. Y_i es la variable respuesta y $EF(\mu_i, \phi)$ denota la distribución de la familia exponencial con media μ_i y parámetro de escala ϕ , A_i es una fila de la matriz del modelo para cualquier componente del modelo estrictamente paramétrico, θ es el vector de parámetros correspondiente, y f_j son funciones suaves de las covariables, x_k . ([Wood \(2006\)](#))

Mientras que el modelo aditivo se estimó por medio de mínimos cuadrados penalizados, el GAM se ajusta mediante la maximización de probabilidad penalizada y se logra por medio de mínimos cuadrados penalizados (PIRLS) y utiliza el algoritmo [5.2.2](#) para la convergencia ([Wood \(2006\)](#); [Hastie and Tibshirani \(1990\)](#)).

5.2. Modelos estadísticos en datos de precipitación

Algoritmo 5.2.2: *Mínimos cuadrados penalizados iterativos (PIRLS)*

(i) Dado el estimado del predictor lineal actual $\hat{\eta}$, y correspondiendo estimado el vector de medias estimado $\hat{\mu}$, calcular:

$$w_i = \frac{1}{V(\mu_i)g'(\mu_i)} \quad y \quad z_i = g'(\mu_i)(y_i - \mu_i) + \eta_i$$

donde $\text{var}(Y_i) = V(\mu_i)\phi$ y g es la función liga.

(ii) Define \mathbf{W} es una matriz diagonal tal que $W_{ii} = w_i$

$$\|\sqrt{\mathbf{W}}\mathbf{z} - \sqrt{\mathbf{W}}\mathbf{X}\beta\|^2 + \sum_{j=1}^n \lambda_j \beta^T \mathbf{S}_j \beta$$

con respecto a β para obtener el nuevo estimado $\hat{\beta}$ y, por lo tanto, estimaciones actualizadas de $\hat{\eta} = \mathbf{X}\hat{\beta}$ y $\hat{\mu}_i = g^{-1}(\hat{\eta}_i)$ El problema de los mínimos cuadrados penalizados se resuelve exactamente como se menciona en la subsección 5.2.2.3

5.2.2.5. Modelos aditivos generalizados vectorizados (VGAM)

Los modelos aditivos generalizados vectorizados (VGAM) se acuñaron debido a su uso de suavizadores de vectores, donde se tiene un vector (y) y las variables x . Los suavizadores multivariados, donde x es un vector, sufren la maldición de la dimensionalidad cuando $\dim(x)$ es grande, por ejemplo, $d > 2$ sin incluir la intersección. El vector x puede manejarse e interpretarse computacionalmente más fácilmente considerando un x_k a la vez (Wood (2006); Hastie and Tibshirani (1990); Yee (2015)).

El modelo VGAM se puede ver de manera general de la siguiente forma:

$$\begin{aligned} \eta(\underline{x}) &= \beta_1 + \sum_{k=2}^d f_k(x_k) \\ &= \mathbf{H}_1 \beta_1 + \sum_{k=2}^d \mathbf{H}_k f_k(x_k) \end{aligned} \quad (5.20)$$

Donde $f_k^*(x_k) = (f_{(1)k}^*(x_k), \dots, f_{Rk}^*(x_k))^T$. Una suma de funciones suavizadas de las covariables individuales, al igual que con las ordinarias GAM (Hastie and Tibshirani (1990)). Las funciones componentes que comprenden $f_k = (f_{(1)k}(x_k), \dots, f_{(M)k}(x_k))^T$ están centrados para la unicidad, y se estiman simultáneamente usando suavizadores de vectores. Conservan la simplicidad de la interpretación que poseen los GAM porque cada x_k tiene un efecto aditivo en 5.20, pero el supuesto de linealidad impuesto por 5.16 es relajado.

Actualmente existen las siguientes aproximaciones para estimar f_k^*

- (i) La regresión por segmentos (Regression splines): ofrecen un compromiso al representar el ajuste como un polinomio por partes. Las regiones son divididas

5.2. Modelos estadísticos en datos de precipitación

por una secuencia de *nudos* (Hastie and Tibshirani (1990))

- (ii) Suavizado de vectores por segmentos (Vector smoothing splines): Ajusta por medio algoritmo 5.2.1 pero aplicado a vectores. Los segmentos vectoriales encajan perfectamente en el enfoque de la función de penalización. (Hastie and Tibshirani (1990))
- (iii) P-segmentos (P-splines): Este enfoque más moderno es más susceptible a la selección e inferencia automática de parámetros de suavizado: la ondulación de las curvas puede elegirse automáticamente por algún criterio objetivo. Amplia los segmentos de regresión penalizando los coeficientes de adyacentes segmentos-B (usados en la práctica por ser numericamente más estables). (Yee (2015))

5.2.3. Modelos aditivos generalizados para localización, escala y forma (GAMLSS)

En la subsección 5.2.2.4 se menciona que dichos modelos la variable respuesta asume de una distribución de la familia exponencial, modelando la media de Y , μ , donde la varianza, la asimetría y la curtosis son funciones de μ y de un parámetro de dispersión constante ϕ . Por lo tanto, en los modelos GLM y GAM, la varianza, la asimetría y la curtosis no se modelan explícitamente en términos de las variables explicativas sino implícitamente a través de su dependencia de μ . (Rigby and Stasinopoulos (2005))

El modelo aditivo generalizado para localización, escala y forma (GAMLSS) (Rigby and Stasinopoulos (2005)), donde el supuesto de familia exponencial se relaja y se reemplaza por una familia de distribución muy general. Así la parte sistémica del modelo se expande para permitir que la media, la varianza, la asimetría y la curtosis se modelen con las variables explicativas.

El ajuste del modelo de un GAMLSS se logra mediante cualquiera de dos algoritmos diferentes, el primer algoritmo (RS) se basa en el algoritmo que se utilizó para el ajuste de los modelos aditivos de dispersión y media de Rigby and Stasinopoulos (1996), mientras que el segundo (CG) se basa en el algoritmo (Verosimilitud penalizada) de Cole and Green (1992).

El modelo GAMLSS, siendo más general que los modelos GAM (5.19) o GLM (5.16), se presenta como:

$$\begin{aligned}
 Y &\stackrel{\text{ind}}{\sim} D(\mu, \sigma, \nu, \tau) \\
 g_1(\mu) &= \mathbf{X}_1 \underline{\beta}_1 + s_{1,1}(x_{1,1}) + \dots + s_{1,J_1}(x_{1,J_1}) \\
 g_2(\sigma) &= \mathbf{X}_2 \underline{\beta}_2 + s_{2,1}(x_{2,1}) + \dots + s_{2,J_2}(x_{2,J_2}) \\
 g_3(\nu) &= \mathbf{X}_3 \underline{\beta}_3 + s_{3,1}(x_{3,1}) + \dots + s_{3,J_3}(x_{3,J_3}) \\
 g_4(\tau) &= \mathbf{X}_4 \underline{\beta}_4 + s_{4,1}(x_{4,1}) + \dots + s_{4,J_4}(x_{4,J_4})
 \end{aligned} \tag{5.21}$$

donde $D(\mu, \sigma, \nu, \tau)$ es una distribución de 4 parámetros de la variable respuesta Y , además ν y τ son parámetros de forma que son asociados a la asimetría y la curtosis de la distribución. x_k son las matrices de diseño que incorporan los términos aditivos lineales en el modelo, k son los parámetros de coeficientes lineales y

5.3. Requerimientos hídricos del cultivo del frijol

$s_{kj}(x_{kj})$ representan funciones de suavizado para las variables explicativas x_{kj} , para $k = (1, 2, 3, 4)$ y $j = (1, \dots, J_k)$. (Stasinopoulos et al. (2017))

Tenga en cuenta que las variables explicativas cuantitativas en las X pueden ser iguales o diferentes del x_{kj} en los suavizadores. Los vectores $g_1(\mu), g_2(\sigma), g_3(\nu)$ y $g_4(\tau)$ se denominan predictores de μ, σ, ν y τ respectivamente. (Stasinopoulos et al. (2017)) Los comentarios más importantes relacionados al modelo (Stasinopoulos et al. (2017)), son:

Distribuciones La forma de la distribución $D(\mu, \sigma, \nu, \tau)$ es general y sólo implica que la distribución debe ser paramétrica. Se puede modelar a un conjunto de 100 distribuciones discretas, continuas y mixtas (Stasinopoulos (2018)) incluyendo algunas que tienen gran asimetría y curtosis. Además:

- Crear nuevas distribuciones es muy fácil.
- Cualquier distribución puede ser truncada a la izquierda, a la derecha o truncada por ambos lados.
- Permite modelar variables censuradas y de respuesta de intervalo.
- Cualquier distribución puede ser mezclado para crear distribuciones mezcla.
- Las distribución continuas discretizadas puede ser creada de las variables respuesta discreta
- Cualquier distribución continua en $(-\infty, \infty)$ puede ser transformados en $(0, \infty)$ o $(0, 1)$ usando el tipo de argumentos con las opciones log o logit.

Términos aditivos Los modelos GAMLSS permiten funciones paramétricas lineales o no lineales, o funciones de suavizado no paramétricas de variables explicativas. Permite los términos aditivos, algunos son:

- segmentos P (segmentos B penalizados)(P-splines)
- segmentos de suavizado cúbico (cubic smoothing splines)
- ajuste de curva de LOESS (locally estimated scatterplot smoothing)
- (vii) polinomios fraccionales (fractional polynomials)
- (viii) efectos aleatorios (random effects)
- (ix) regresión ridge
- (x) ajustes paramétricos no lineales (nonlinear parametric fits)

Métodos de ajuste Los modelos paramétricos GAMLSS 5.21 (sin funciones de suavizado) es ajustado por las estimaciones de máxima verosimilitud penalizadas.

5.3. Requerimientos hídricos del cultivo del frijol

Para obtener los requerimientos hídricos del cultivo del frijol, también conocido como la Evapotranspiración del cultivo (ET_C) en condiciones estándar, es decir, sin problemas tales como densidad del cultivo, estrés por salinidad o enfermedades, por

5.3. Requerimientos hídricos del cultivo del frijol

ejemplo; se obtiene a través de la siguiente ecuación:

$$ET_C = k_C * ET_0 \quad (5.22)$$

Donde ET_C es determinada por el efecto de las condiciones climáticas por medio de ET_0 y las características del cultivo, en este caso, del frijol k_C . Por lo que, el ET_C cambia conforme cambia la región, finalmente fueron los cuantiles para obtener las probabilidades y los periodos de retorno.

Para obtener ET_C el procedimiento es:

- Obtener el ET_0 de la estación
- Identificar las etapas del cultivo y sus duraciones
- Identificar los k_C para cada etapa en los cuadros, en caso de utilizarlo para cálculos de planeación.
- Calcular ET_C como en la ecuación 5.22

5.3.1. Estimación de la Evapotranspiración potencial (ET_0)

ET_0 es considerado la evapotranspiración de referencia, donde se considera que es una superficie hipotética con pasto de 0.12 m de altura, un albedo de 0.23 y una superficie fija de 70 s/m (un suelo moderadamente seco resultado de un riego constante) (Allen et al. (1998); Howell and Evett (2004)), este puede ser calculado por medio del método de Penman-Monteith, que se resume en la ecuación.

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (5.23)$$

Donde ET_0 evapotranspiración de referencia (mm/da), R_n Radiación neta en la superficie del cultivo ($MJ/m^2/da$), G Densidad del flujo de calor del suelo ($MJ/m^2/da$), T Temperatura media (C), u_2 velocidad del viento a 2 m de altura (m/s), e_s presión de vapor a saturación (kPa), e_a presión de vapor actual (kPa), $e_s - e_a$ déficit de presión de saturación de vapor (kPa), Δ pendiente en la curva de presión de vapor (kPa/C), γ constante psicométrico (kPa/C). Para calcular el constante psicométrico ($gamma$):

$$\gamma = 0.665 * 10^{-3} P \quad (5.24)$$

donde P es la presión atmosférica, con la ecuación.

$$P = 101.3 \left(\frac{293 - 0.0065z}{293} \right)^{5.26} \quad (5.25)$$

donde z son los metros sobre el nivel del mar. Para calcular la presión de vapor a saturación (e_s).

$$e^s = \frac{e^0(T_{max}) + e^0(T_{min})}{2} \quad (5.26)$$

5.3. Requerimientos hídricos del cultivo del frijol

donde:

$$e^0(T) = 0.6108 \exp \left[\frac{17.27T}{T + 237.3} \right] \quad (5.27)$$

Para calcular la pendiente en la curva de presión de vapor (Δ):

$$\Delta = \frac{4098 * e^0(T_{med})}{(T_{med} + 237.3)^2} \quad (5.28)$$

donde:

$$T_{med} = \frac{T_{max} + T_{min}}{2} \quad (5.29)$$

Para calcular la presión de vapor actual (E_a):

$$e_a = e^0(T_{min}) \frac{HR_{max}}{100} \quad (5.30)$$

donde HR_{max} es la humedad relativa máxima. Para calcular la velocidad del viento a 2 m de altura (u_2):

$$u_2 = u_z \frac{4.87}{\ln(67.8z - 5.42)} \quad (5.31)$$

donde u_z es la velocidad del viento a una altura z y z es la altura del medidor sobre la superficie. Para el cálculo de la radiación neta en la superficie del cultivo (R_n) y G densidad del flujo de calor del suelo (G) lo describe [Allen et al. \(1998\)](#) (41 pag.)

5.3.2. Estimación del Coeficiente del cultivo simple (k_C)

Como se mencionó anteriormente, k_C resume las características del cultivo y la evapotranspiración del suelo en un sólo coeficiente, que permite ajustar la ET_0 , se sugiere que la duración de las etapas se realice en campo, sin embargo, si no se cuenta con dicha información, se puede obtener del cuadro 5.1.

Cuadro 5.1: Duración de las etapas del cultivo del frijol [Doorenbos and Pruitt. \(1977\)](#)

Cultivo	Duración (días)					Región
	Inicio	Desarrollo	Medio	Tardía	Total	
Frijol maduro	20	30	40	20	110	Clima Continental

Para cada etapa de cultivo, tiene diferentes requerimientos hídricos, es decir cambia su coeficiente de corrección del cultivo k_C conforme el periodo de crecimiento, formando una curva. Sólo son necesarios 3 valores de dicha curva para describirla y construirla:

- El coeficiente al inicio del periodo de crecimiento k_{ini} .
- El coeficiente de la etapa media k_{med} .
- El coeficiente del final de la etapa tardía k_{end} .

5.3. Requerimientos hídricos del cultivo del frijol

Cuadro 5.2: Valores predeterminados de k_C para el periodo de crecimiento del cultivo del frijol [Doorenbos and Kassam \(1979\)](#)

Cultivo	Coeficiente del cultivo			Altura (cm.)
	Inicio ¹	Medio ²	Tardío ³	
Frijol maduro	0.4	1.15	0.35	40

Del mismo modo que con la duración del periodo de crecimiento del cultivo, también para ser más precisos se debe calcular los coeficientes y existen cuadros con valores aproximados de los coeficientes de corrección, que consideran el cultivo y una altura máxima del mismo (ya que k_C cambia con la altura de la planta), como se muestra en el cuadro [5.2](#).

CAPÍTULO 6

PROPUESTA METODOLÓGICA

6.1. Características de los datos

6.1.1. Precipitación (variable respuesta)

En el presente trabajo se utilizó la base de datos generada por la Comisión Nacional del Agua ([CONAGUA \(2019\)](#)) contiene una gran cantidad de variables meteorológicas, tales como temperatura máxima, mínima y promedio, Humedad Relativa, velocidad del viento, etc.; para realizar la extracción de los datos de precipitación por estación, mes y año, fue necesario el desarrollo de un código en el programa R ([R Core Team \(2019\)](#)), el cual se muestra en el apéndice [A.1](#).

Los datos de mensuales de precipitación tienen información de el año 1890 al 2017, sin embargo, estos datos presentan las siguientes características:

- Todas las estaciones tienen una gran cantidad de datos faltantes desde 1890 a 1960.
- La proporción de datos faltantes de 1960 a 2015 es menor.
- Algunas estaciones tienen datos de menos 20 años, y al tener muy poca información, deben ser descartadas.

Por lo que, se seleccionaron las estaciones que tienen menos del 15% de datos faltantes de precipitación en un periodo de tiempo continuo y además que tenga al menos 20 años de información.

Las estaciones tienen una clave que lo compone por los primeros dos números son el estado donde se localizan y los siguientes números son el número de estación conforme fue colocado en el estado. Por ejemplo, para la estación 13120 del estado de Hidalgo, se muestra en el cuadro [6.1](#):

6.2. Ajuste y selección de modelos probabilísticos a datos de precipitación

Cuadro 6.1: Claves de las estaciones climatológicas CONAGUA

Edo	# estación
13	120

6.1.2. Ubicación, Altitud e Índices Oceánico-Atmosféricos (variables explicatorias)

Al ser estaciones climatológicas (CONAGUA (2019)) también presentan datos de ubicación (latitud (Lat.) y longitud (Long.)), además de la altitud sobre el nivel del mar (MSNM) que son útiles para entender como se comportan espacialmente los datos, conociendo que la precipitación en una región es influenciada por la ubicación de dicha región, fungen como variables explicatorias de la variable respuesta (precipitación). En el cuadro 6.2 se muestra algunas características de las series de tiempo de los índices oceánico-atmosféricos que se considera puedan ser variables explicatorias del comportamiento de la precipitación en México (sección 4.2) .

Cuadro 6.2: Algunas características de los índices oceánico-atmosféricos

Índice	Serie de tiempo		Presentación
	Inicio	Final	
ONI (4.2.1.1)	Enero/1950	Febrero/2020	Mensual
NPI (4.2.2.1)	Enero/1899	Junio/2019	Mensual
PDO index (4.2.3.1)	Enero/1854	Febrero/2020	Mensual
NAO index (4.2.4.1)	Enero/1950	Marzo/2020	Mensual
AMO (4.2.5)	Diciembre/1855	Junio/2016	Mensual
AMO smoothed (4.2.5)	Enero/1859	Febrero/2020	Mensual
ALPI (4.2.6)	1900	2015	Anual

6.2. Ajuste y selección de modelos probabilísticos a datos de precipitación

En la sección 5.1 se comentó de las distintas distribuciones que son asociadas a la precipitación. Sin embargo, fue necesario verificar si los datos obtenidos cumplen con alguna de las distribuciones de la teoría; debido a la gran amplitud de distribuciones, donde $x > 0$, se decidió analizarla con el procedimiento Severity de SAS (SAS Institute Inc. (2012)). Después se buscó encontrar las distribuciones que mejor ajustaran a los datos, descritas en la sección 5.1: Gamma (eq.5.4), Gamma Generalizada (5.6), GB2 (eq.5.9) y GEV (eq.5.13), por medio de los paquetes de R: *stats* (R Core Team (2019)), *GB2* (Graf and Nedyalkova. (2015)), *MASS* (Venables and Ripley (2002)) y *edv* (Stephenson (2002)), el cual se verificó con las gráficas de distribución empírica,

6.3. Selección de los modelos

comparándolas, con las gráficas de las distribuciones ajustadas, de este modo se buscó descartar la (las) distribución (distribuciones) que menor ajuste tuvo a los datos. También se puede observar el mejor ajuste de la distribución por medio de la función $GAIC()$ que forma parte del paquete *gamlss* (Rigby and Stasinopoulos (2005)). El método de estimación de parámetros de las distribuciones empleadas es el de Máxima Verosimilitud (para detalles ver Casella and Berger (2002)), el cual es utilizado por el software empleado.

6.3. Selección de los modelos

Se ajustaron los modelos lineales generalizados (GLM) utilizando la función “glm” de la librería “stats” del programa R R Core Team (2019), los modelos aditivos generalizados vectorizados (VGAM) empleando la librería “VGAM” de R desarrollada por (Yee (2015); Yee (2010)) y los modelos aditivos generalizados para localización, escala y forma (GAMLSS) se usó la librería “gamlss” de R (Rigby and Stasinopoulos (2005)) para las distribuciones seleccionadas del procedimiento de la sección anterior (6.2. Escogiendo aquellas que no tienen problemas con la convergencia en las iteraciones para obtener las estimaciones de parámetros de las funciones, esto ocurrió para el modelo VGAM para la distribución Valores Extremos Generalizada (GEV) y los modelos GAMLSS para las distribuciones Beta Generalizado tipo II (GB2), Gamma Generalizada (GG) y Gamma (G), todos estos modelos son nulos, es decir, sin efecto de covariables.

6.4. Selección de las variables explicatorias

Las variables explicatorias utilizadas en el presente estudio son: la ubicación (Latitud y Longitud) y la altitud de la estación, el índice oceánico del Niño del mes y, por lo explicado por el marco teórico, el resto de los índices oceánico-atmosféricos van en interacción con el índice oceánico del Niño, ya que ayuda a explicar a su variabilidad, de tal modo, al modelo completo VGAM es utilizada en función *step4* del paquete *VGAM* (Yee (2015); Yee (2010)) para encontrar las variables significativas obteniendo el modelo con el AIC más pequeño que se compara con el modelo VGAM nulo obtener el mejor modelo VGAM de la distribución GEV. Se resume en el cuadro 6.3 como se obtuvieron las variables significativas para cada estación.

Mientras para el modelo completo GAMLSS es utilizada en función *STEPGAIC* del paquete *gamlss* (Rigby and Stasinopoulos (2005)) para encontrar las variables significativas obteniendo el modelo con el GAIC más pequeño que se compara con el modelo GAMLSS nulo obtener el mejor modelo GAMLSS de las distribuciones Gamma (GA), Gamma Generalizada (GG) y Beta Generalizada tipo II (GB2). Se resume en el cuadro 6.4 como se obtuvieron las variables significativas para cada estación.

6.5. Validación cruzada

Cuadro 6.3: Modelos VGAM comparados para cada estación

Modelos	Variables	
	Respuesta	Explicatorias
Modelo 0	PP_Mes	~ 1
Modelo 1	PP_Mes	$\sim \text{ONI_Mes} + (\text{ONI:NAO})_Mes + (\text{ONI:NPI})_Mes + (\text{ONI:ALPI})_Mes + (\text{ONI:PDO})_Mes$
Modelo 2	PP_Mes	Step4(modelo 1)

Cuadro 6.4: Modelos GAMLSS comparados para cada estación

Modelos	Variables	
	Respuesta	Explicatorias
Modelo 0	PP_Mes	~ 1
Modelo 1	PP_Mes	$\sim \text{ONI_Mes} + (\text{ONI:NAO})_Mes + (\text{ONI:NPI})_Mes + (\text{ONI:ALPI})_Mes + (\text{ONI:PDO})_Mes$
Modelo 2	PP_Mes	STEPGAIC(modelo 1)

6.5. Validación cruzada

Por medio de la función *rand* del paquete *pracma* (Borchers (2019)) del programa R, se divide la base de datos de precipitación en una proporción de 70/30; con el 70 % se ajustan los modelos tanto VGAM como GAMLSS y se utiliza los modelos para predecir predecir el 30 restante. Posteriormente, se obtienen los residuales, y con ellos se calcula la suma de cuadrados del error que definió el mejor modelo para la estación en cuestión, además del AIC, sin embargo, como el objetivo del presente trabajo es predecir los valores de precipitación, se dió más peso a la suma de cuadrados del error para definir el mejor modelo.

6.6. Estimación de probabilidades y tiempos de retorno

Para que el frijol pueda prosperar una región (considerando solamente la limitante es la precipitación y es bajo el supuesto que es cultivo de temporal) es necesario calcular la Evapotranspiración del cultivo (ET_C) (5.3.1), que fueron los cuantiles para estimar las probabilidades y con ello los periodos de retorno.

6.6.1. Estimación de los cuantiles para obtener sus probabilidades (Evapotranspiración del cultivo de frijol [ET_C])

Para obtener las probabilidades para que el frijol pueda prosperar una región (considerando solamente la limitante es la precipitación y es bajo el supuesto que es cultivo

6.6. Estimación de probabilidades y tiempos de retorno

de temporal) es necesario calcular la Evapotranspiración del cultivo (ET_C)(5.3.1). Entonces se utilizó los datos de las mismas estaciones, tales como , la temperatura máxima y mínima, HR_{max} , etc., para el calculo de la Evapotranspiración Potencial (ET_0) para cada estación, y finalmente se multiplica por los kc obtenidos por el cuadro 5.2 para el cultivo de frijol, obteniendo finalmente la Evapotranspiración del cultivo (ET_C).

Ya que la fecha de inicio del cultivo depende de las condiciones de cada región, se consideraron dos fechas de inicio de siembra, 15 de mayo y 15 de junio, durando 110 días de ciclo del cultivo (5.1), la fecha del final del cultivo, que es 2 de septiembre y 3 de octubre, respectivamente.

6.6.2. Estimación de las probabilidades y los tiempos de retorno

Para estimar las probabilidades se deben estimar los cuantiles, es decir, los requerimientos hídricos de cultivo del frijol (5.3).

6.6.2.1. Estimación de los cuantiles

Las estaciones tienen dentro de sus datos la temperatura máxima y mínima (T_{max} ; T_{min}), la humedad relativa máxima y mínima (HR_{max} ; HR_{min}), velocidad del viento a 10 m de altura (u_{10}) (de la Federación (2013)) y Radiación Solar (R). Por lo que, son los datos necesarios para calcular ET_0 (mm/día) para cada estación.

Posteriormente, definiendo como inicio de siembra el 15 de mayo y el 15 de junio, es decir, hay dos escenarios. Se utilizaron la duración de las etapas fenológicas del frijol (Cuadro 5.1), para definir los días de duración de las etapas fenológicas por mes. Finalmente, se calcula la ET_C mensual del cultivo, separando el k_C (definido en el cuadro 5.2) respectivo para cada etapa y mes.

6.6.2.2. Estimación de las probabilidades y periodos de retorno

El modelo VGAM con distribución GEV se calcularon las probabilidades por medio de la función $pGEV$ que forma parte del paquete VGAM de R. Del mismo modo, en el paquete GAMLSS tienen sus propias funciones para calcular probabilidades **pGA** para los modelos Gamma (GA), **pGB2** para los modelos Beta Generalizados tipo II (GB2) y **pGG** para los modelos Gamma Generalizada (GG), aunque se hace una función que permite calcular la probabilidad si el valor del cuantil es 0.

$$prob_{frijol} = k; x = 0 \quad (6.1)$$

$$(1 - k)(p_{dist}); x > 0 \quad (6.2)$$

donde $prob_{frijol}$ es la probabilidad calculada, k es la proporción de ceros dentro de los datos y p_{dist} es la probabilidad calculada por medio de las funciones mencionadas en el párrafo anterior.

6.6. Estimación de probabilidades y tiempos de retorno

A estas probabilidades (p_{frijol}) se denominan, en este documento, de ahora en adelante, como p , y se calculan para cada estación.

Se debe tomar en cuenta que los cuantiles son los valores mínimos de requerimiento hídrico para que el cultivo de frijol de un rendimiento óptimo, y con ello tenga una mayor rentabilidad. Sabiendo esto el valor que se buscó fue $q = 1 - p$.

Teniendo q se utilizó para calcular los periodos de retorno (T) que se calculan de la siguiente forma:

$$T = \frac{1}{q} \quad (6.3)$$

Cada T esta asociado a cada estación y se guardaron las probabilidades q y los periodos de retorno con su clave de estación, que fueron la llave para unir las bases de datos que permitieron su mapeo.

6.6.2.3. Generación de mapas con las probabilidades y los tiempos de retorno

Las estaciones tienen una clave que lo compone por los primeros dos números son el estado donde se localizan y los siguientes números son el número de estación conforme fue colocado en el estado, lo que sirve para hacer una llave que permita conectar Los resultados con los datos de ubicación que nos sirve para ponerlos en un plano espacial. Se realizó este último paso por medio del programa "QGIS" de R ([QGIS Development Team \(2009\)](#)).

CAPÍTULO 7

RESULTADOS

7.1. Estaciones meteorológicas consideradas en el estudio

Las estaciones que forman parte del Altiplano Mexicano 4.3 son 641 de las cuales 37 no cumplen con el requisito de tener al menos 20 años, quedando para el análisis 604 estaciones climatológicas (figura 7.1, apendice B). El porcentaje de datos faltantes de las 604 estaciones es, en promedio, 9.88 % para mayo, 10.00 % para junio, 9.38 % para julio, 10.42 % para agosto, 11.10 % para septiembre, y 10.87 % para octubre.

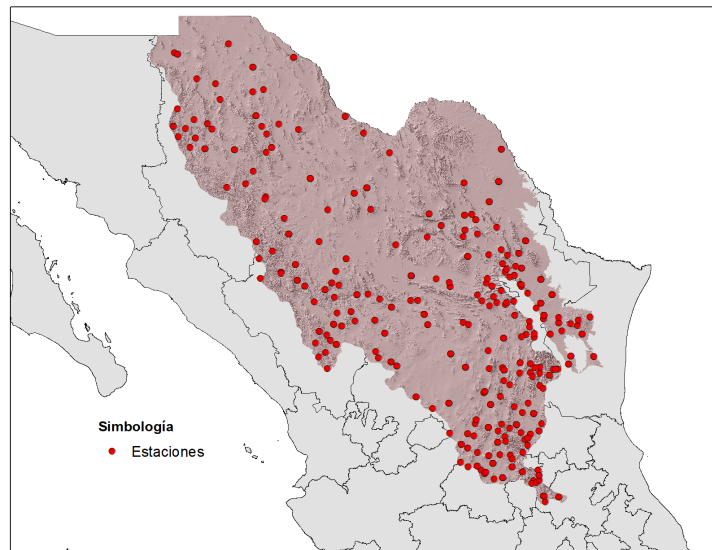


Figura 7.1: Ubicación de las estaciones utilizadas en el presente estudio

7.2. Ajuste de las distribuciones G, GG, GB2 y GEV

7.2. Ajuste de las distribuciones G, GG, GB2 y GEV

7.2.1. Exploración

Se realizó una exploración de los datos (los promedios de cada mes) usando proc Severity de SAS (SAS Institute Inc. (2012)), que por medio del criterio de información de Akaike (AIC), elige la distribución que mejor se ajusta al conjunto de datos dado, para las 604 estaciones. Como ejemplo de ilustración, en el cuadro 7.1 se muestran los resultados del ajuste resultante de proc severity para la estación 32020 Fresnillo, Zacatecas. Como se puede observar (Cuadro 7.1), aunque en la teoría dice que la distribución más aceptada que tiene un mejor ajuste es la gamma ponderada 5.4, la que mejor ajusto es la Gauss Inversa, que forma parte de la familia del Beta Generalizada tipo II.

Cuadro 7.1: Resultados del procedimiento Severity de SAS para la estación 32020 Fresnillo, Zacatecas

Distribution	Parameter	Estimate	StdErr	tValue	Probt	Station
Gauss Inversa	Theta	64.2402226	32.9146917	1.9517188	0.07470363	32020

En el estado de Zacatecas (fig. 7.2), por ejemplo, se tiene que las distribuciones que ajustan, bajo las distribuciones predefinidas del proc severity, son la Gauss Inversa (Igauss) (63%), la Burr tipo XII (Burr)(12%), Pareto Generalizada (Gdp)(2%), Pareto tipo II (Pareto) (3%) y la Log-normal (Logn)(20%).

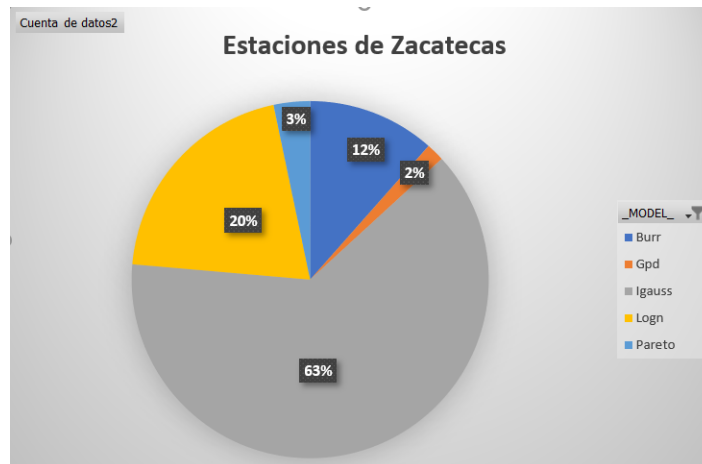


Figura 7.2: Función de distribución empírica de los meses de mayo a octubre de la estación 32020 Fresnillo, Zac.

7.2.2. Ajuste de distribución

Debido a que los datos de precipitación tienen valores no negativos, se tuvo que programar una ponderación para calcular las densidades de manera correcta, por supuesto,

7.2. Ajuste de las distribuciones G, GG, GB2 y GEV

en las distribuciones cuyo soporte no tiene al valor 0; las distribuciones elegidas son Gamma (G), Gamma Generalizada (GG), Beta Generalizada tipo II (GB2) y Valores Extremos Generalizada (GEV), como ejemplo de las 604 estaciones analizadas, se tiene en la figura 7.3, donde se observa la distribución empírica de los datos de precipitación para los meses de Mayo a Octubre.

De manera general, se observa que la distribución G no ajusta de buena manera a los datos de precipitación para ninguno de los meses analizados, que ocurre en todas las estaciones analizadas, también muestra que las distribuciones GB2, GG y GEV tienen mejores ajustes a los datos, note que en el mes de Junio la distribución GG no ajusta tal como lo hace las distribuciones GB2 y GEV; las distribuciones GB2 y GG muchas veces coinciden, y esto tiene sentido ya que dentro de la familia de la distribución GB2 tiene a la distribución GG.

Para el resto de las estaciones los resultados son más o menos similares, por lo que este ejemplo resume lo observado en las 604 estaciones.




Figura 7.3: Función de distribución empírica y teorica (GA GG GB2 GEV) de los meses de mayo a octubre de la estación 32020 Fresnillo, Zac.

7.3. Selección de Modelos y Variables

7.3. Selección de Modelos y Variables

7.3.1. Selección de Modelos

Se probaron los modelos GLM, VGAM y GAMLSS para las distribuciones analizadas en 7.2.2, obteniendo que los modelos convergen con los datos para todas las estaciones y tienen AIC más pequeño para cada distribución, los modelos VGAM GEV, los modelos GAMLSS para las distribuciones Gamma, Beta Generalizada tipo II y Gamma Generalizada. En 7.3.1, 7.3.2, 7.3.3 y 7.3.4 se muestran los modelos nulos que tuvieron convergencia para la estación 32020, para los modelos VGAM GEV, y GAMLSS GEB, GG, y G del mes de mayo, respectivamente.

Note que el modelo GAMLSS que tiene menor AIC es el modelo GAMLSS con distribución Gamma (7.3.4) aunque el modelo GAMLSS-GG es mayor por sólo unas décimas (7.3.3), en general, los modelos GAMLSS tuvieron un menor AIC que el modelo GEV.

Resultado 7.3.1: Modelo nulo VGAM GEV de mayo Est. 32020

```
Call: vglm(formula = data1.PP_May ~ 1, family = gevff, data =
na.omit(PP_MayGEV2), trace = TRUE)
Coefficients:
(Intercept):1 (Intercept):2 (Intercept):3
      3.8645361      1.7641482      0.4226847
Degrees of Freedom: 120 Total; 117 Residual
Log-likelihood: -154.7651
AICvglm(mod032020GEVmay)
315.53
```

Resultado 7.3.2: Modelo nulo GAMLSS GB2 de mayo Est. 32020

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_May ~ 1, family = GB2(),
data = na.omit(PP_Maydat), method = mixed(1, 1000))
Mu Coefficients:      Sigma Coefficients:
(Intercept)          (Intercept)
      3.179             -0.6026
Nu Coefficients:      Tau Coefficients:
(Intercept)          (Intercept)
      1.451             2.065
Degrees of Freedom for the fit: 4 Residual Deg. of Freedom   30
Global Deviance:      238.679
                   AIC:      246.679
                   SBC:      252.785
```

7.3. Selección de Modelos y Variables

Resultado 7.3.3: *Modelo nulo GAMLSS GG de mayo Est. 32020*

```
Family: c("GG", "generalised Gamma Lopatatsidis-Green")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_May ~ 1, family = GG,
data = na.omit(PP_Maydat), method = mixed(1, 1000))
Mu Coefficients:      Sigma Coefficients:
(Intercept)          (Intercept)
      2.039              0.1225
Nu Coefficients:
(Intercept)
      0.1222
Degrees of Freedom for the fit: 3 Residual Deg. of Freedom   31
Global Deviance:      238.166
                   AIC:      244.166
                   SBC:      248.745
```

Resultado 7.3.4: *Modelo nulo GAMLSS G de mayo Est. 32020*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)

Call: gamlss(formula = PP_May ~ 1, family = GA,
data = na.omit(PP_Maydat), method = mixed(1, 1000))
Mu Coefficients:      Sigma Coefficients:
(Intercept)          (Intercept)
      2.531           -0.003257
Degrees of Freedom for the fit: 2 Residual Deg. of Freedom   32
Global Deviance:      240.084
                   AIC:      244.084
                   SBC:      247.137
```

7.3.2. Selección de Variables

Con los modelos seleccionados anteriormente [7.3.1](#), se probaron el conjunto de variables como aparece en el cuadro ([7.2](#)), para cada modelo se compararon el modelo nulo (0), el completo (1) y el obtenido por el proceso de Stepwise (2). Cada modelo tiene diferencias por el número de parámetros y el proceso que siguen para su cálculo, eso se explicará en cada caso.

7.3.2.1. Modelo VGAM GEV

En el cuadro [7.2](#) se muestran los valores de AIC obtenidos para los modelos VGAM GEV, cuando se muestra NA, quiere decir que dicho modelo no pudo converger y por lo tanto, no existe, por lo que se excluye del análisis. El proceso de los modelos

7.3. Selección de Modelos y Variables

VGAM no requiere calcular otros parámetros ya que como se explicó en (parte teórica del VGAM), este modelo sólo calcula la media de la variable respuesta ($\mu(Y)$).

Cuadro 7.2: AIC y p-valor de la prueba de χ^2 para los modelos VGAM GEV

Est	Mes	AIC0GEV	AIC1GEV	AIC2GEV	chisqp01GEV	chisqp02GEV
32020	May	315.530278	307.378122	NA	0.00276163	NA
32020	Jun	364.574638	367.343265	363.391785	0.20399366	0.06629246
32020	Jul	407.620494	413.285311	408.49836	0.50223332	0.20991196
32020	Ago	396.423856	391.842171	389.801289	0.01230757	0.00552817
32020	Sep	387.108182	394.027198	387.108182	0.68750192	1
32020	Oct	328.293117	333.130942	326.886958	0.39641059	0.06495348

Para el mes de Mayo, el mejor modelo resultó ser el completo (7.3.5), con un AIC de 307.37, sobre el modelo nulo (AIC 315.53), en este caso, el modelo resultado del stepwise no se calculó. El mes de Junio, el mejor modelo es el modelo reducido (AIC 363.39), que es el obtenido por el método stepwise y se muestra en el resultado 7.3.6; para julio el modelo nulo es que tuvo un menor AIC (7.3.7), en agosto (7.3.8) el modelo reducido tuvo el menor AIC. En septiembre tanto el modelo nulo como el modelo reducido tienen el mismo AIC, por lo que se elige el modelo nulo (7.3.9). En octubre (7.3.10), el modelo reducido es el modelo con AIC menor.

Resultado 7.3.5: Modelo completo VGAM GEV para el mes de mayo

```
Call: vglm(formula = data1.PP_May ~ ONI_May + ONI_May:PDO_May +
  ONI_May:NAO_May + ONI_May:NPI_May + ONI_May:ALPI,
  family = gevff, data = na.omit(PP_MayGEV2), scale = ~1,
  shape = ~1, trace = TRUE)
Coefficients:
  (Intercept):1      (Intercept):2      (Intercept):3      ONI_May
    1.3376887      1.3185840      0.6697509      2836.6531392
  ONI_May:PDO_May  ONI_May:NAO_May  ONI_May:NPI_May  ONI_May:ALPI
    3.7775502      0.8493554      -2.7965343      0.5030548
Degrees of Freedom: 120 Total; 112 Residual
Log-likelihood: -145.6891
```


7.3. Selección de Modelos y Variables

Resultado 7.3.6: *Modelo nulo VGAM GEV para el mes de junio*

```
Call: vglm(formula = data1.PP_Jun ~ ONI_Jun + ONI_Jun:PDO_Jun +
ONI_Jun:NAO_Jun, family = gevff, data = na.omit(PP_JunGEV2),
scale = ~1, shape = ~1, trace = TRUE)
Coefficients:
  (Intercept):1  (Intercept):2  (Intercept):3      ONI_Jun
      33.4756219      3.2102281      -0.4215887      12.1988392
ONI_Jun:PDO_Jun ONI_Jun:NAO_Jun
24.3747825      -21.9657942
Degrees of Freedom: 108 Total; 102 Residual
Log-likelihood: -175.6959
```

Resultado 7.3.7: *Modelo nulo VGAM GEV para el mes de julio**

```
Call: vglm(formula = data1.PP_Jul ~ ONI_Jul + ONI_Jul:PDO_Jul,
family = gevff, data = na.omit(PP_JulGEV2), scale = ~1,
shape = ~1, trace = TRUE)
Coefficients:
  (Intercept):1  (Intercept):2  (Intercept):3      ONI_Jul
      65.5291317      3.6001205      -0.4898208      -13.2057564
ONI_Jul:PDO_Jul
-17.6709770
Degrees of Freedom: 114 Total; 109 Residual
Log-likelihood: -199.2492
```

Resultado 7.3.8: *Modelo reducido VGAM GEV para el mes de agosto*

```
Call:
vglm(formula = data1.PP_Ago ~ ONI_Ago + ONI_Ago:PDO_Ago +
ONI_Ago:NAO_Ago, family = gevff, data = na.omit(PP_AgoGEV2),
scale = ~1, shape = ~1, trace = TRUE)
Coefficients:
  (Intercept):1  (Intercept):2  (Intercept):3      ONI_Ago
      80.6949268      3.5515741      -0.8065982      -17.7128396
ONI_Ago:PDO_Ago ONI_Ago:NAO_Ago
      13.0207491      -43.0670157
Degrees of Freedom: 111 Total; 105 Residual
Log-likelihood: -188.9006
```

7.3. Selección de Modelos y Variables

Resultado 7.3.9: Modelo nulo VGAM GEV para el mes de septiembre

```
Call:
vglm(formula = data1.PP_Sep ~ 1, family = gevff,
data = na.omit(PP_SepGEV2), trace = TRUE)
Coefficients:
(Intercept):1 (Intercept):2 (Intercept):3
 53.4347115    3.6851239   -0.6028222
Degrees of Freedom: 108 Total; 105 Residual
Log-likelihood: -190.5541
```

Resultado 7.3.10: Modelo reducido VGAM GEV para el mes de octubre

```
Call:
vglm(formula = data1.PP_Oct ~ ONI_Oct, family = gevff,
data = na.omit(PP_OctGEV2), scale = ~1, shape = ~1, trace = TRUE)
Coefficients:
(Intercept):1 (Intercept):2 (Intercept):3      ONI_Oct
 20.286530    2.840334   -0.675193    5.585511
Degrees of Freedom: 108 Total; 104 Residual
Log-likelihood: -159.4435
```

7.3.2.2. Modelo GAMLSS GB2

En el cuadro 7.3 se muestran los valores de AIC obtenidos para los modelos GAMLSS GB2. El proceso de los modelos GAMLSS requiere calcular otros parámetros ya que como se explicó en (5.2.3), este modelo calcula la media, la varianza, la asimetría y la curtosis de la variable respuesta $(\mu(Y), \sigma(Y), \nu(Y), \tau(Y))$, este modelo requiere de los cuatro parámetros.

Cuadro 7.3: AIC para los modelos GAMLSS GB2

Est	Mes	AIC0GEB	AIC1GEB	AIC2GEB
32020	May	246.679318	237.514041	237.514041
32020	Jun	361.638753	369.161825	361.638753
32020	Jul	391.448811	388.992116	385.381072
32020	Ago	396.514815	393.012976	390.019816
32020	Sep	386.558833	388.252929	383.251269
32020	Oct	312.45144	318.269119	312.317366

Para el mes de Mayo, el mejor modelo resultó ser el reducido (7.3.11), con un AIC de 237.51. El mes de Junio, los modelos que tienen un mejor AIC son el nulo y el reducido, es decir, las variables no influyen en la variable respuesta (7.3.6); para julio

7.3. Selección de Modelos y Variables

el modelo reducido es que tuvo un menor AIC (7.3.13), en agosto (7.3.14) el modelo reducido tuvo el menor AIC. En septiembre el modelo reducido el AIC más pequeño (7.3.15). En octubre (7.3.16), el modelo reducido es el modelo con AIC menor, por sólo unas décimas.

Resultado 7.3.11: Modelo reducido GAMLSS GB2 para el mes de mayo

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_May ~ ONI_May + ONI_May:PDO_May +
  ONI_May:NAO_May + ONI_May:NPI_May + ONI_May:ALPIMay,
  family = GB2(), data = na.omit(PP_Maydat), method = mixed(1,
  1000), trace = FALSE, sigma.formula = ~1, nu.formula = ~1,
  tau.formula = ~1)
Mu Coefficients:
  (Intercept)          ONI_May  ONI_May:PDO_May  ONI_May:NAO_May
      0.2526      -583.2390         0.9240         -0.9432
ONI_May:NPI_May  ONI_May:ALPIMay
      0.5731         -0.6866
Sigma Coefficients:  Nu Coefficients:  Tau Coefficients:
(Intercept)          (Intercept)          (Intercept)
      0.05746          1.863          0.6192
Degrees of Freedom for the fit: 9 Residual Deg. of Freedom  25
Global Deviance:      219.514
                   AIC:      237.514
                   SBC:      251.251
```

Resultado 7.3.12: Modelo nulo GAMLSS GB2 para el mes de junio

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Jun ~ 1, family = GB2(),
  data = na.omit(PP_Jundat), method = mixed(1, 1000), trace = FALSE,
  sigma.formula = ~1, nu.formula = ~1, tau.formula = ~1)
Mu Coefficients:  Sigma Coefficients:
(Intercept)          (Intercept)
      6.46          0.6567
Nu Coefficients:  Tau Coefficients:
(Intercept)          (Intercept)
     -0.4917          3.923
Degrees of Freedom for the fit: 4 Residual Deg. of Freedom  32
Global Deviance:      353.639
                   AIC:      361.639
                   SBC:      367.973
```

7.3. Selección de Modelos y Variables

Resultado 7.3.13: *Modelo reducido GAMLSS GB2 para el mes de julio*

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Jul ~ ONI_Jul + ONI_Jul:NAO_Jul +
  ONI_Jul:ALPIJul, family = GB2(), data = na.omit(PP_Juldat),
  method = mixed(1, 1000), trace = FALSE, sigma.formula = ~1,
  nu.formula = ~1, tau.formula = ~1)
Mu Coefficients:
  (Intercept)      ONI_Jul  ONI_Jul:NAO_Jul  ONI_Jul:ALPIJul
    4.254401      -0.427561      -0.001025      -0.073648
Sigma Coefficients: Nu Coefficients: Tau Coefficients:
  (Intercept)      (Intercept)      (Intercept)
    3.525          -2.412           -2.637
Degrees of Freedom for the fit: 7 Residual Deg. of Freedom  30
Global Deviance:      371.381
                   AIC:      385.381
                   SBC:      396.657
```

Resultado 7.3.14: *Modelo reducido GAMLSS GB2 para el mes de agosto*

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Ago ~ ONI_Ago + ONI_Ago:NAO_Ago,
  family = GB2(), data = na.omit(PP_Agodat), method = mixed(1,
  1000), trace = FALSE, sigma.formula = ~1, nu.formula = ~1,
  tau.formula = ~1)
Mu Coefficients:
  (Intercept)      ONI_Ago  ONI_Ago:NAO_Ago
    5.0004        -0.1719        -0.3807
Sigma Coefficients: Nu Coefficients: Tau Coefficients:
  (Intercept)      (Intercept)      (Intercept)
    0.7262          0.5563          1.429
Degrees of Freedom for the fit: 6 Residual Deg. of Freedom  31
Global Deviance:      378.02
                   AIC:      390.02
                   SBC:      399.685
```

7.3. Selección de Modelos y Variables

Resultado 7.3.15: Modelo reducido GAMLSS GB2 para el mes de septiembre

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Sep ~ ONI_Sep + ONI_Sep:PDO_Sep +
  ONI_Sep:NAO_Sep, family = GB2(), data = na.omit(PP_Sepdat),
  method = mixed(1, 1000), trace = FALSE, sigma.formula = ~1,
  nu.formula = ~1, tau.formula = ~1)
Mu Coefficients:
  (Intercept)      ONI_Sep  ONI_Sep:PDO_Sep  ONI_Sep:NAO_Sep
    4.7768      -0.2540      -0.1837      -0.2492
Sigma Coefficients: Nu Coefficients: Tau Coefficients:
  (Intercept)      (Intercept)      (Intercept)
    2.911      -2.753      -1.314
Degrees of Freedom for the fit: 7 Residual Deg. of Freedom  29
Global Deviance:      369.251
      AIC:      383.251
      SBC:      394.336
```

Resultado 7.3.16: Modelo reducido GAMLSS GB2 para el mes de octubre

```
Family: c("GB2", "Generalized beta 2 (i.e. of the second kind)")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Oct ~ ONI_Oct + ONI_Oct:NAO_Oct,
  family = GB2(), data = na.omit(PP_Octdat), method = mixed(1,
  1000), trace = FALSE, sigma.formula = ~1, nu.formula = ~1,
  tau.formula = ~1)
Mu Coefficients:
  (Intercept)      ONI_Oct  ONI_Oct:NAO_Oct
    3.5398      0.2907      0.1257
Sigma Coefficients: Nu Coefficients: Tau Coefficients:
  (Intercept)      (Intercept)      (Intercept)
    2.764      -2.693      -2.046
Degrees of Freedom for the fit: 6 Residual Deg. of Freedom  28
Global Deviance:      300.317
      AIC:      312.317
      SBC:      321.476
```

7.3.2.3. Modelo GAMLSS Gamma Generalizada

En el cuadro 7.4 se muestran los valores de AIC obtenidos para los modelos GAMLSS GG. El proceso de los modelos GAMLSS requiere calcular otros parámetros ya que como se explicó en (5.2.3), este modelo calcula la media, la varianza y la asimetría

7.3. Selección de Modelos y Variables

y la curtosis de la variable respuesta $(\mu(Y), \sigma(Y), \nu(Y))$, este modelo requiere tres de los cuatro parámetros.

Cuadro 7.4: AIC para los modelos GAMLSS GG

Est	Mes	AIC0GG	AIC1GG	AIC2GG
32020	May	244.166	NA	NA
32020	Jun	359.515	NA	NA
32020	Jul	388.987	NA	NA
32020	Ago	394.185	NA	NA
32020	Sep	384.698	NA	NA
32020	Oct	312.818	NA	NA

Note que para ningún mes hubo convergencia en los modelos con las variables, por lo que sólo se obtuvieron los modelos nulos.

7.3.2.4. Modelo GAMLSS Gamma

En el cuadro 7.5 se muestran los valores de AIC obtenidos para los modelos GAMLSS G. El proceso de los modelos GAMLSS requiere calcular otros parámetros ya que como se explicó en (5.2.3), este modelo calcula la media, la varianza, la asimetría y la curtosis de la variable respuesta $(\mu(Y), \sigma(Y))$, este modelo requiere dos de los cuatro parámetros.

Cuadro 7.5: AIC para los modelos GAMLSS G

Est	Mes	AIC0GA	AIC1GA	AIC2GA
32020	May	244.083793	237.442092	237.442092
32020	Jun	358.905048	365.872921	358.905048
32020	Jul	390.043062	391.918647	386.668783
32020	Ago	392.489127	389.643612	385.703905
32020	Sep	384.141675	389.209549	384.352076
32020	Oct	310.958764	317.652334	309.073622

Para el mes de Mayo, el mejor modelo resultó ser el reducido (7.3.17), con un AIC de 237.44. El mes de Junio, los modelos que tienen un mejor AIC son el nulo y el reducido, es decir, las variables no influyen en la variable respuesta (7.3.18); para julio el modelo reducido es que tuvo un menor AIC (7.3.19), en agosto (7.3.20) el modelo reducido tuvo el menor AIC. En septiembre el modelo nulo tiene el AIC más pequeño (7.3.21). En octubre (7.3.22), el modelo reducido es el modelo con AIC menor, además que en este modelo el parámetro $\sigma(Y)$ si tiene influencia del fenómeno del Niño.

7.3. Selección de Modelos y Variables

Resultado 7.3.17: *Modelo reducido GAMLSS G para el mes de mayo*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_May ~ ONI_May + ONI_May:PDO_May +
  ONI_May:NAO_May + ONI_May:NPI_May + ONI_May:ALPIMay,
  family = GA, data = na.omit(PP_Maydat), method = mixed(1,
  1000), trace = FALSE, sigma.formula = ~1)
Mu Coefficients:
  (Intercept)          ONI_May  ONI_May:PDO_May  ONI_May:NAO_May
      2.0203        -759.8428         0.8696         -1.1065
ONI_May:NPI_May  ONI_May:ALPIMay
      0.7469         -0.9197
Sigma Coefficients:
(Intercept)
  -0.1996
Degrees of Freedom for the fit: 7 Residual Deg. of Freedom  27
Global Deviance:      223.442
                   AIC:      237.442
                   SBC:      248.127
```

Resultado 7.3.18: *Modelo nulo GAMLSS G para el mes de junio*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Jun ~ 1, family = GA,
  data = na.omit(PP_Jundat), method = mixed(1, 1000))
Mu Coefficients:
(Intercept)
      3.992
Sigma Coefficients:
(Intercept)
  -0.2447
Degrees of Freedom for the fit: 2 Residual Deg. of Freedom  34
Global Deviance:      354.905
                   AIC:      358.905
                   SBC:      362.072
```

7.3. Selección de Modelos y Variables

Resultado 7.3.19: *Modelo reducido GAMLSS G para el mes de julio*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call:
gamlss(formula = PP_Jul ~ ONI_Jul, family = GA,
data = na.omit(PP_Juldat), method = mixed(1, 1000),
trace = FALSE, sigma.formula = ~1)
Mu Coefficients:
(Intercept)      ONI_Jul
    4.4827      -0.3282
Sigma Coefficients:
(Intercept)
   -0.6315
Degrees of Freedom for the fit: 3 Residual Deg. of Freedom   34
Global Deviance:      380.669
                   AIC:      386.669
                   SBC:      391.502
```

Resultado 7.3.20: *Modelo reducido GAMLSS G para el mes de agosto*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Ago ~ ONI_Ago + ONI_Ago:NAO_Ago,
family = GA, data = na.omit(PP_Agodat), method = mixed(1,
1000), trace = FALSE, sigma.formula = ~1)
Mu Coefficients:
(Intercept)      ONI_Ago  ONI_Ago:NAO_Ago
    4.5967      -0.1534      -0.3696
Sigma Coefficients:
(Intercept)
   -0.7678
Degrees of Freedom for the fit: 4 Residual Deg. of Freedom   33
Global Deviance:      377.704
                   AIC:      385.704
                   SBC:      392.148
```


7.3. Selección de Modelos y Variables

Resultado 7.3.21: *Modelo nulo GAMLSS G para el mes de septiembre*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Sep ~ 1, family = GA,
data = na.omit(PP_Sepdat), method = mixed(1, 1000))
Mu Coefficients:
(Intercept)
      4.362
Sigma Coefficients:
(Intercept)
     -0.2858
Degrees of Freedom for the fit: 2 Residual Deg. of Freedom   34
Global Deviance:      380.142
                   AIC:      384.142
                   SBC:      387.309
```

Resultado 7.3.22: *Modelo reducido GAMLSS G para el mes de octubre*

```
Family: c("GA", "Gamma")
Fitting method: mixed(1, 1000)
Call: gamlss(formula = PP_Oct ~ 1, sigma.formula = ~ONI_Oct,
family = GA, data = na.omit(PP_Octdat), method = mixed(1,
1000), trace = FALSE)
Mu Coefficients:
(Intercept)
      3.587
Sigma Coefficients:
(Intercept)   ONI_Oct
     -0.1843     -0.3029
Degrees of Freedom for the fit: 3 Residual Deg. of Freedom   31
Global Deviance:      303.074
                   AIC:      309.074
                   SBC:      313.653
```

7.3.3. Comparación entre modelos

En el cuadro 7.6 se muestra el mejor modelo para cada mes por el modelo que mejor ajustó por distribución, los valores que están en NA las situaciones cuyos los modelos nulos tuvieron mejor ajuste que los modelos completos o reducidos. Note que el tipo de modelo que tiene menos modelos nulos es GAMLSS GB2 y el que tiene más modelos con mejores ajustes fue VGAM GEV.

7.4. Probabilidades y periodos de retorno

Cuadro 7.6: SCE de los modelos VGAM GEV, GAMLSS GB2 y GAMLSS G

Mes	SumGEV	SumGEB	SumG
Mayo	1529.15707	14429.0229	13679.033
Junio	91479.4168	NA	NA
Julio	NA	37691.7035	41305.7049
Agosto	36356.3031	126344.081	42500.9792
Septiembre	NA	66711.9314	NA
Octubre	53763.8238	26401.0821	24384.0686

7.4. Probabilidades y periodos de retorno

Teniendo el modelo que cuenta con mejores ajustes el modelo VGAM GEV es que se utilizó para realizar el cálculo de las probabilidades, sin embargo para eso, es necesario observar los resultados de los cuantiles, mostrados en la sección 7.4.1.

7.4.1. Estimación de cuantiles

Los cuantiles (ET_C) que se calcularon, tal como se explica en la sección 5.3, cambian dependiendo las condiciones de la estación. Ya que existen dos fechas posibles para iniciar la siembra del cultivo de frijol se consideraron dos escenarios. El primero se muestra en el cuadro 7.7 con el requerimiento hídrico del cultivo del frijol para la estación 32020 Fresnillo, Zacatecas, si se siembra el 15 de mayo, mientras, el segundo escenario en el cuadro 7.8 con el requerimiento hídrico del cultivo del frijol para la estación 32020 Fresnillo, Zacatecas, si se siembra el 15 de junio. Ambos escenarios, en todo su ciclo.

Cuadro 7.7: Requerimiento hídrico del cultivo de frijol, estación 32020, fecha de siembra: 15-May

Estación	ET_C Mayo	ET_C Junio	ET_C Julio	ET_C Agosto	ET_C Septiembre
32020	28.916129	56.668	139.763065	83.0806452	16.562

Cuadro 7.8: Requerimiento hídrico del cultivo de frijol, estación 32020, fecha de siembra: 15-Jun

Estación	ET_C Junio	ET_C Julio	ET_C Agosto	ET_C Septiembre	ET_C Octubre
32020	27.42	56.668	128.244516	76.076	14.9709677

7.4. Probabilidades y periodos de retorno

7.4.2. Estimación de probabilidades y periodos de retorno

Teniendo los cuantiles para calcular las probabilidades con los parámetros calculados en los modelos VGAM GEV para todas las 604 estaciones, en los dos escenarios, en 7.4.2.1 y 7.4.2.2, se muestra en ejemplo del cálculo de probabilidades y periodos de retorno de las 604 estaciones.

7.4.2.1. Escenario 1

El escenario 1 es cuando la siembra es el 15 de mayo, como un ciclo de cultivo que dura 120 días, en el cuadro 7.9 donde se muestran las probabilidades calculadas con el modelo VGAM GEV.

Cuadro 7.9: Probabilidades calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 1

Est	LatD	LonD	p1May	p1Jun	p1Jul	p1Ago	p1Sep
32020	23.17	-102.89	0.176	0.186	0.073	0.509	1.000

Mientras, en el cuadro 7.10 muestra los periodos de retorno calculadas con el mismo modelo. Los periodos de retorno son en años, es decir, en mayo, para que la precipitación alcanzase en el requerimiento hídrico mínimo, es de cada 6 (5.6) años aproximadamente.

Cuadro 7.10: Periodo de retorno calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 1

Est	LatD	LonD	T1May	T1Jun	T1Jul	T1Ago	T1Sep
32020	23.17	-102.89	5.693	5.389	13.645	1.966	1.000

7.4.2.2. Escenario 2

El escenario 1 es cuando la siembra es el 15 de junio, como un ciclo de cultivo que dura 120 días, en el cuadro 7.11 donde se muestran las probabilidades calculadas con el modelo VGAM GEV.

Cuadro 7.11: Probabilidades calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 2

Est	LatD	LonD	p2Jun	p2Jul	p2Ago	p2Sep	p2Oct
32020	23.17	-102.890	1.000	1.000	0.107	0.189	0.999

Mientras, en el cuadro 7.12 muestra los periodos de retorno calculadas con el mismo

7.4. Probabilidades y periodos de retorno

modelo. Los periodos de retorno son en años, es decir, en junio, para que la precipitación alcanzase en el requerimiento hídrico mínimo, es de cada año aproximadamente.

Cuadro 7.12: Periodo de retorno calculadas con el modelo VGAM GEV para la estación 32020 en el escenario 2

Est	LatD	LonD	T2Jun	T2Jul	T2Ago	T2Sep	T2Oct
32020	23.17	-102.890	1.000	1.000	9.352	5.299	1.000

7.4.3. Mapas de periodos de retorno

Finalmente, con el cálculo de las probabilidades y los periodos de retorno de las 604 estaciones, se realizaron los mapas con los contornos de los periodos de retorno (años) por cada mes y por el ciclo del cultivo.

7.4.3.1. Escenario 1

En la figura 7.4 se muestran los mapas de mayo, junio, julio, agosto y septiembre, para mayo se puede observar que en la parte noroeste del mapa el periodo de retorno de 9 a 10 años, mientras que el sureste el periodo de retorno es de cada 1 a 2 años. Para junio, el periodo de retorno de 9 a 10 años se mueve al centro del mapa, mientras que el periodo de retorno de 1 a 2 años se mantiene en el sureste.

En julio, el periodo de retorno de 1 a 2 años se concentra al suroeste de Chihuahua y partes de San Luis Potosí mientras en el resto de la región se impone el periodo de retorno de 9 a 10 años; para agosto, los periodos de retorno de 1 a 2 se concentran en el oeste y el sureste, los periodos de retorno de 9 a 10 se concentra en el centro, por último, en septiembre, la mayor parte de la región esta en el rango de los periodos de retorno de 1 a 2 años.

La figura 7.5 muestra los periodos de retorno del ciclo del cultivo de frijol bajo el escenario 1, se puede observar que los periodos de retorno de 1 a 2 años se concentran en el suroeste de la región del altiplano, principalmente al oeste del estado de Durango, mientras que los periodos de retorno de 9 a 10 años se concentran al norte de la región, principalmente en los estados de Chihuahua, Coahuila y Nuevo León. Al este de San Luis Potosí se encuentran pequeñas regiones con periodos de retorno de 1 a 2 años.

7.4. Probabilidades y periodos de retorno

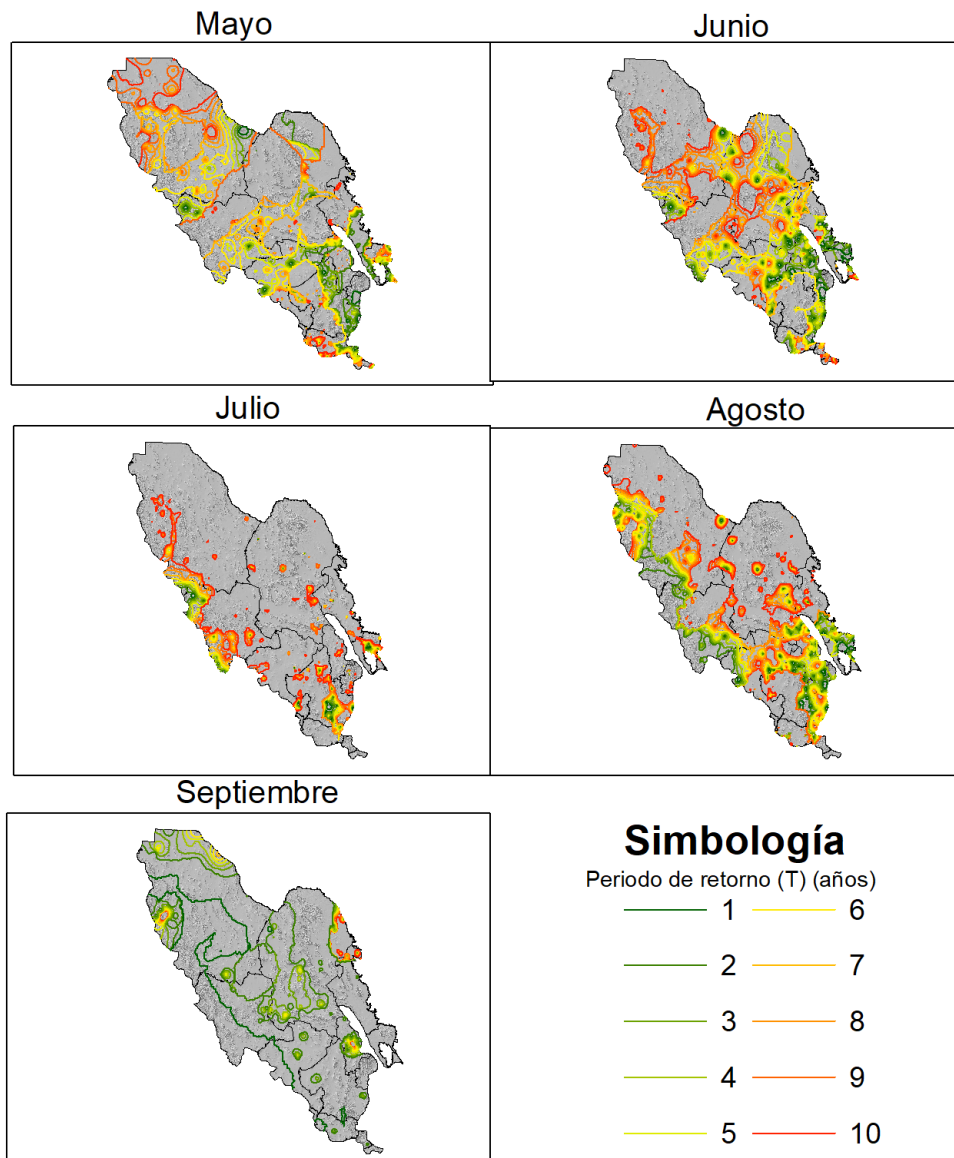


Figura 7.4: Mapas de los periodos de retorno (años) por mes para el escenario 1

7.4. Probabilidades y periodos de retorno

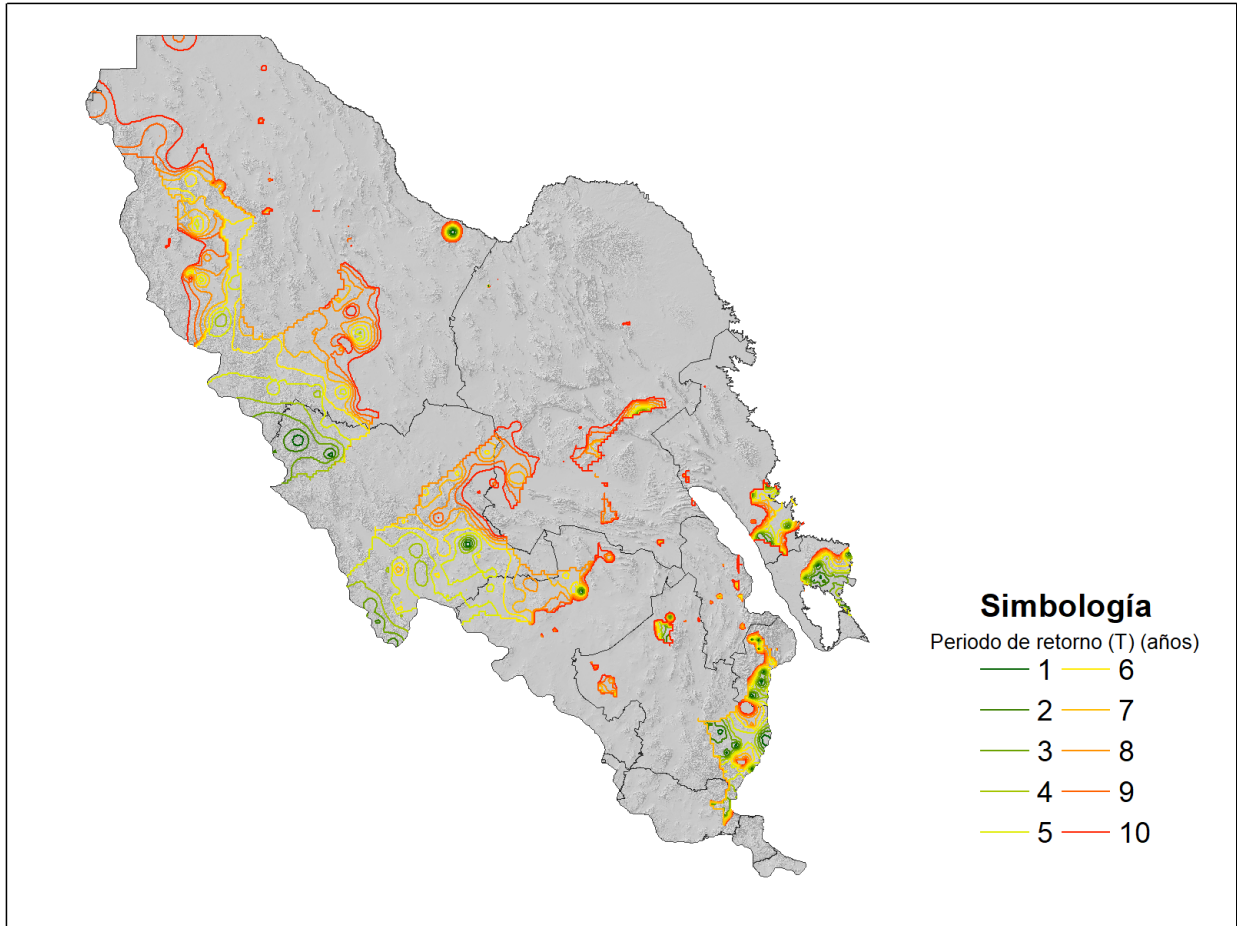


Figura 7.5: Mapa de los periodos de retorno (años) con el ciclo de cultivo para el escenario 1

7.4.3.2. Escenario 2

En la figura 7.6 se muestran los mapas de junio, julio, agosto, septiembre y octubre, para junio se puede observar que en la parte noroeste del mapa (norte de Chihuahua) el periodo de retorno de 9 a 10 años, mientras que en el oeste y sureste el periodo de retorno es de cada 1 a 2 años. Para julio, el periodo de retorno de 9 a 10 años se mueve al centro del mapa, mientras que el periodo de retorno de 1 a 2 años se mantiene en el oeste y sureste.

7.4. Probabilidades y periodos de retorno

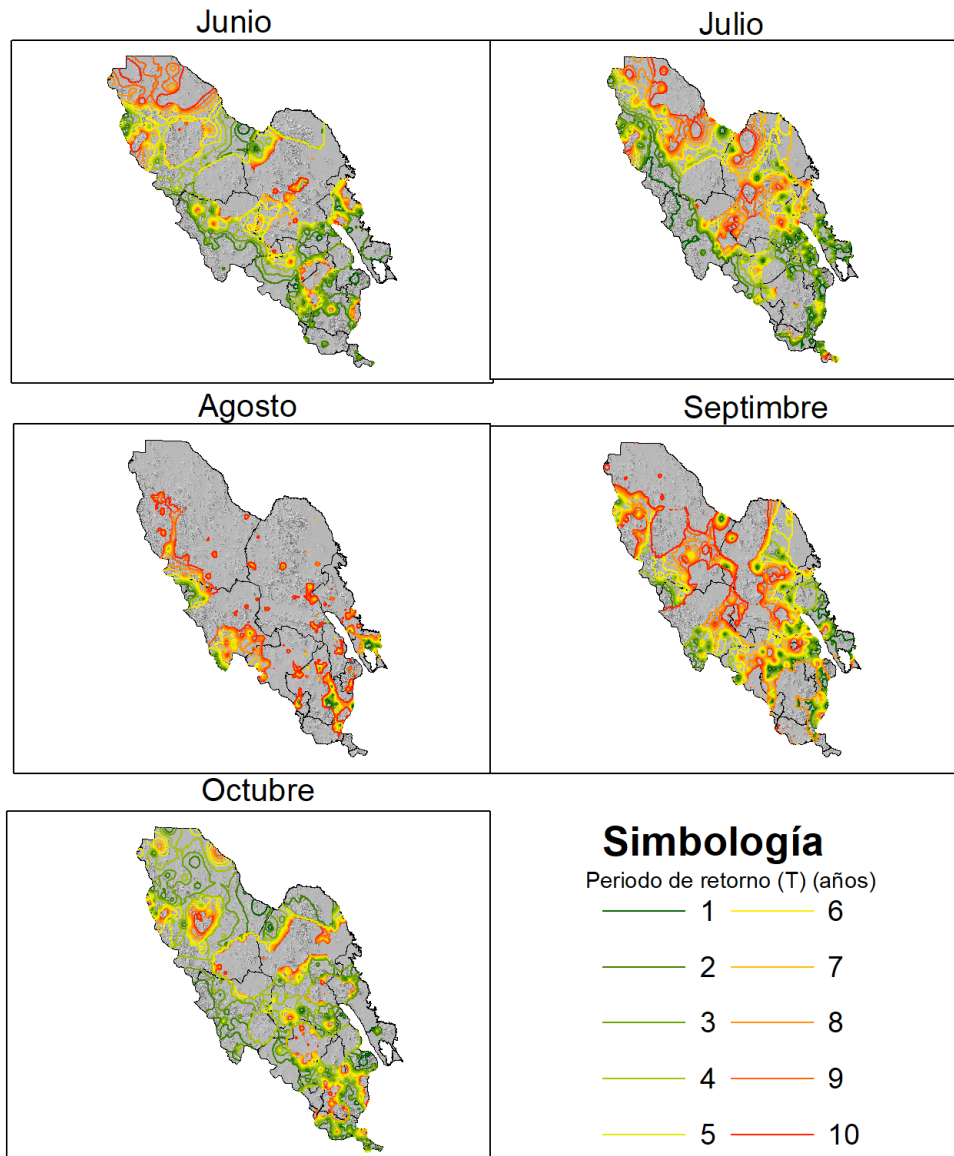


Figura 7.6: Mapas de los periodos de retorno (años) por mes para el escenario 2

En agosto, el periodo de retorno de 1 a 2 años se concentra al suroeste de Chihuahua y partes de San Luis Potosí mientras en el resto de la región se impone el periodo de retorno de 9 a 10 años o más; para septiembre, los periodos de retorno de 1 a 2 se concentran en el oeste y el sureste, los periodos de retorno de 9 a 10 se concentra en el centro, por último, en septiembre, la mayor parte de la región esta en el rango de los periodos de retorno de 1 a 2 años.

La figura 7.7 muestra los periodos de retorno del ciclo del cultivo de frijol bajo el

7.4. Probabilidades y periodos de retorno

escenario 1, se puede observar que los periodos de retorno de 1 a 2 años se concentran en el suroeste de la región del altiplano, principalmente al oeste del estado de Durango, mientras que los periodos de retorno de 9 a 10 años se concentran al norte de la región, principalmente en los estados de Chihuahua , Coahuila y Nuevo León. Al este de San Luis Potosí se encuentran pequeñas regiones con periodos de retorno de 1 a 2 años.

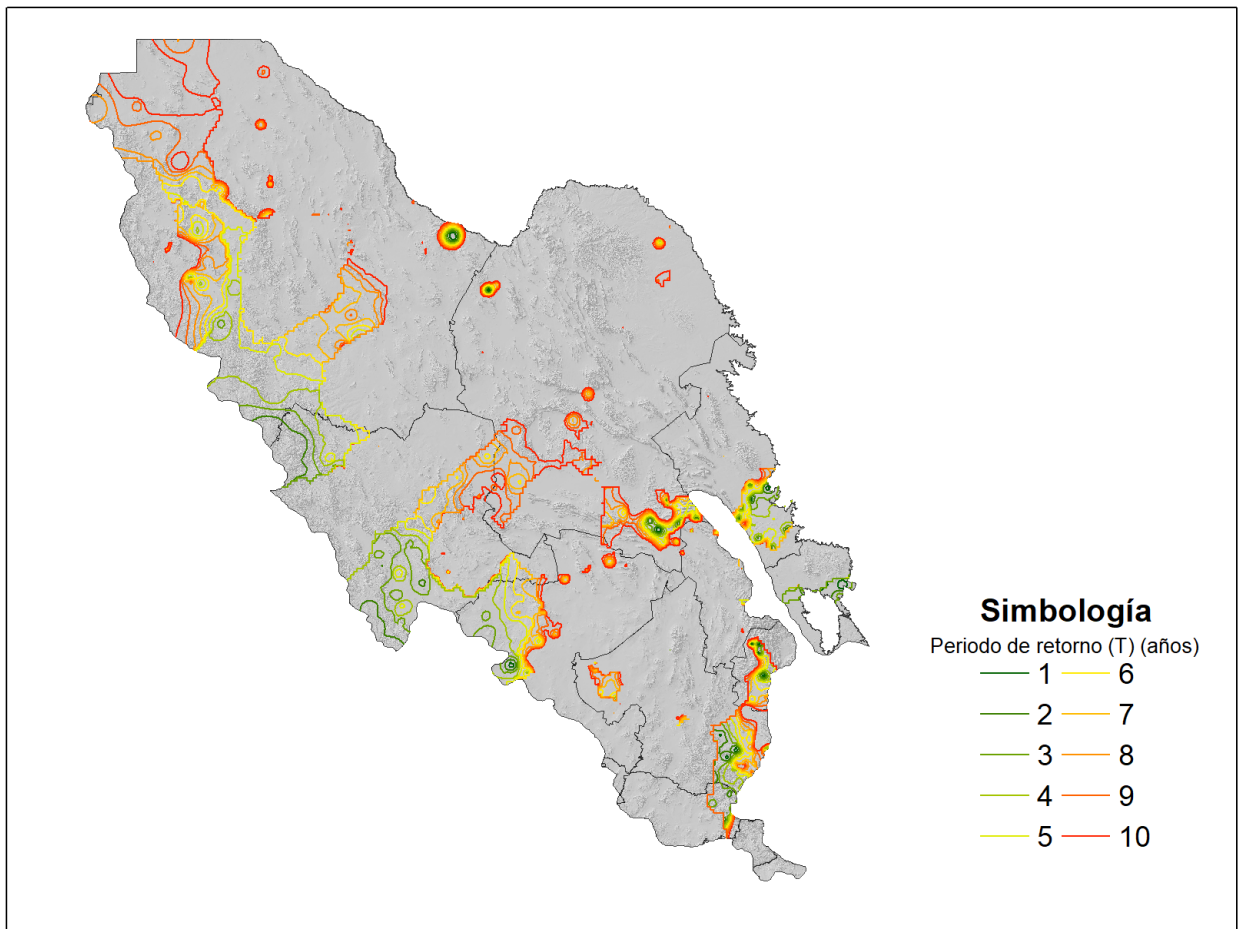


Figura 7.7: Mapa de los periodos de retorno (años) con el ciclo de cultivo para el escenario 2

CAPÍTULO 8

CONCLUSIONES

Los datos de precipitación en México tienen un número de registros muy variable, además que hay muchas estaciones que tienen 30 % de datos faltantes, lo cual es muy importante, mejorar la toma de datos, ya que tener una mejor calidad de datos permitiría tomar decisiones con mejores modelos.

Las distribuciones con mejor ajuste fueron la distribución de valores extremos generalizada (GEV), la beta generalizada tipo II (GB2) y la gamma generalizada (GG) sobre la distribución gamma (G), tal como se observa en la figura 7.3 para las estaciones del Altiplano Mexicano, diferente a la distribución preferida para ajustar los datos de precipitación (5.1.1).

En los modelos VGAM GEV, GAMLSS GB2 y GAMLSS G se encontró que los índices oceánico-atmosféricos si están relacionados con la precipitación de algunos meses, los meses de Junio y Septiembre son los que tuvieron mayor problema para encontrar dicha relación ya que los modelos resultados del método stepwise consideraba que los modelos nulos tenían un mejor ajuste. Algo de sumo interés es, que los modelos GAMLSS G ajustan mejor son con pocas variables, como ejemplo, el modelo del mes de octubre, donde μ solo tiene el intercepto y σ ajustó el intercepto y la variable ONI_{Oct} (7.3.22)

Para ambos escenarios, el suroeste de la región del Altiplano Mexicano tiene periodos de retorno de 1 a 2 años, aunque cabe destacar que en el escenario 2 los periodos de retorno 1 a 2 años abarcan hasta parte del estado de Zacatecas (fig. 7.7).

Se recomienda investigar la razón por la cual no hubo convergencia en los modelos GAMLSS GG, ya que, comparando todos los modelos nulos (7.3.1), estos tenían los mejores ajustes, sin embargo, los modelos no alcanzaban la convergencia, al momento de calcularlos con el paquete GAMLSS.

LITERATURA CITADA

- Agresti, A. (2015). *Foundations of linear and generalized linear models*. John Wiley & Sons.
- Ahrens, C. D. (2009). *Meteorology today: an introduction to weather, climate, and the environment, 9 ed.* Brooks/Cole Cengage Learning.
- Allen, R., Pereira, L., Raes, D., and Smith, M. (1998). Fao irrigation and drainage paper no. 56. *Rome: Food and Agriculture Organization of the United Nations*, 56:26–40.
- Beamish, R. J. and Bouillon, D. R. (1993). Pacific salmon production trends in relation to climate. *Canadian journal of fisheries and aquatic sciences*, 50(5):1002–1016.
- Borchers, H. W. (2019). *pracma: Practical Numerical Math Functions*. R package version 2.2.9.
- Bromirski, P. D., Flick, R. E., and Cayan, D. R. (2003). Storminess variability along the california coast: 1858–2000. *Journal of Climate*, 16(6):982–993.
- Buishand, T. (1978). Some remarks on the use of daily rainfall models. *Journal of Hydrology*, 36(3-4):295–308.
- Burgueno, A., Martinez, M., Lana, X., and Serra, C. (2005). Statistical distributions of the daily rainfall regime in catalonia (northeastern spain) for the years 1950–2000. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 25(10):1381–1403.
- Casella, G. and Berger, R. L. (2002). *Statistical inference*, volume 2. Duxbury Pacific Grove, CA.
- Chen, L. and Singh, V. P. (2017). Generalized beta distribution of the second kind for flood frequency analysis. *Entropy*, 19(6).

LITERATURA CITADA

- Chiang, J. C. and Vimont, D. J. (2004). Analogous pacific and atlantic meridional modes of tropical atmosphere–ocean variability. *Journal of Climate*, 17(21):4143–4158.
- Cole, T. J. and Green, P. J. (1992). Smoothing reference centile curves: the lms method and penalized likelihood. *Statistics in medicine*, 11(10):1305–1319.
- Coles, S., Bawa, J., Trenner, L., and Dorazio, P. (2001). *An Introduction to Statistical Modeling of Extreme Values*. Lecture Notes in Control and Information Sciences. Springer.
- CONAGUA (2019). Registro histórico de datos meteorológicos por estaciones climatológicas.
- CPC-NOAA (2004). Reports to the nation: The north american monsoon, college park, maryland.
- de la Federación, D. O. (2013). Estaciones meteorológicas, climatológicas, e hidrológicas parte 1. NMX-AA-166/1-SCFI-2013.
- Delworth, T. L. and Mann, M. E. (2000). Observed and simulated multidecadal variability in the northern hemisphere. *Climate Dynamics*, 16(9):661–676.
- Doorenbos, J. and Kassam, A. (1979). Efectos del agua sobre el rendimiento de los cultivos. *FAO Irrigation and drainage paper*, (33).
- Doorenbos, J. and Pruitt., W. (1977). Las necesidades de agua de los cultivos. *FAO Irrigation and drainage paper*, (24).
- Duan, J., Sikka, A. K., and Grant, G. E. (1995). A comparison of stochastic models for generating daily precipitation at the hj andrews experimental forest.
- Edwards, D. (1997). Characteristics of 20th century drought in the united states at multiple time scales. Master’s thesis.
- Felch, R. (1978). Drought: Characteristics and assessment. north american droughts, nj rosenberg, ed., aaas selected symposia, vol. 15.
- Ferrari, G. T. and Ozaki, V. (2014). Missing data imputation of climate datasets: Implications to modeling extreme drought events. *Revista Brasileira de Meteorologia*, 29(1):21–28.
- García, E. and Trejo, R. I. (1994). La presencia del monzón en el noroeste de méxico. *Investigaciones geográficas*, (28):33–64.
- Graf, M. and Nedyalkova., D. (2015). *GB2: Generalized Beta Distribution of the Second Kind: Properties, Likelihood, Estimation*. R package version 2.1.
- Gray, W. M. (1984). Atlantic seasonal hurricane frequency. part i: El niño and 30 mb quasi-biennial oscillation influences. *Monthly Weather Review*, 112(9):1649–1668.

LITERATURA CITADA

- Hastie, T. and Tibshirani, R. (1990). Generalized additive models london chapman and hall. *Inc.*
- Howell, T. and Evett, S. (2004). The penman-monteith method.
- Huang, B., Angel, W., Boyer, T., Cheng, L., Chepurin, G., Freeman, E., Liu, C., and Zhang, H.-M. (2018). Evaluating sst analyses with independent ocean profile observations. *Journal of Climate*, 31(13):5015–5030.
- Hurrell, J. (1995). Decadal trends in the north atlantic oscillation. *Science (New York, N. Y.)*, 269:676–9.
- Hurrell, J. W., Kushnir, Y., Ottersen, G., and Visbeck, M. (2013). *An Overview of the North Atlantic Oscillation*, pages 1–35. American Geophysical Union (AGU).
- INEGI. (2001). Conjunto de datos vectoriales fisiográficos. continuo nacional. escala 1:1 000 000. serie i.
- INEGI. (2008). Características edafológicas, fisiográficas, climáticas e hidrográficas de méxico.
- INEGI (2008). Características edafológicas, fisiográficas, climáticas e hidrográficas de méxico. inegi.
- Jenkinson, A. F. (1955). The frequency distribution of the annual maximum (or minimum) values of meteorological elements. *Quarterly Journal of the Royal Meteorological Society*, 81(348):158–171.
- JISAO (2017). The pacific decadal oscillation (pdo).
- King, J. R., McFarlane, G. A., and Beamish, R. J. (2001). Incorporating the dynamics of marine systems into the stock assessment and management of sablefish. *Progress in Oceanography*, 49(1-4):619–639.
- Kingery, R. K, J. (1992). A stochastic analysis of the drought in colorado. Msc thesis, colorado state university, fort collins, colorado, 171 pp.
- Kushnir, Y. (1999). Climatology: Europe’s winter prospects. *Nature*, 398:289–291.
- Lagos, B., Ferreira, G., and Valenzuela, M. (2011). A proposed reparametrization of gamma distribution for the analysis of data of rainfall-runoff driven pollution. *Proyecciones (Antofagasta, On line)*, 30(3):415–439.
- Landsberg, H. E. (1982). Climatic aspects of droughts. *Bulletin of the American Meteorological Society*, 63(6):593–596.
- Larson, J., Zhou, Y., and Higgins, R. W. (2005). Characteristics of landfalling tropical cyclones in the united states and mexico: Climatology and interannual variability. *Journal of Climate*, 18(8):1247–1262.

LITERATURA CITADA

- L'Heureux, M. L., Collins, D. C., and Hu, Z.-Z. (2013). Linear trends in sea surface temperature of the tropical pacific ocean and implications for the el niño-southern oscillation. *Climate Dynamics*, 40(5-6):1223–1236.
- Linkin, M. E. and Nigam, S. (2008). The north pacific oscillation–west pacific teleconnection pattern: Mature-phase structure and winter impacts. *Journal of Climate*, 21(9):1979–1997.
- Magaña, V. O., Vázquez, J. L., Pérez, J. L., and Pérez, J. B. (2003). Impact of el niño on precipitation in mexico. *Geofísica internacional*, 42(3):313–330.
- Mantua, N. J., Hare, S. R., Zhang, Y., Wallace, J. M., and Francis, R. C. (1997). A pacific interdecadal climate oscillation with impacts on salmon production. *Bulletin of the american Meteorological Society*, 78(6):1069–1080.
- María Engracia Hernández, G. C. and Alfaro, G. (2007). *Mitos y realidades de la sequía en México*. Number I.6.3 in Temas selectos de Geografía de México. Instituto de Geografía UNAM.
- Martinez-Villalobos, C. and Neelin, J. D. (2019). Why do precipitation intensities tend to follow gamma distributions? *Journal of the Atmospheric Sciences*, 76(11):3611–3631.
- McDonald, J. B. (1984). Some generalized functions for the size distribution of income. *Econometrica*, 52(3):647–663.
- McDonald, J. B. (2008). Some generalized functions for the size distribution of income. In *Modeling Income Distributions and Lorenz Curves*, pages 37–55. Springer.
- McFarlane, G. A., King, J. R., and Beamish, R. J. (2000). Have there been recent changes in climate? ask the fish. *Progress in Oceanography*, 47(2-4):147–169.
- McKee, T., D. N. . K. J. (1993). The relationship of drought frequency and duration to time scales. *American Meteorological Society*, pages 179–184.
- McPhaden, M. J., Zebiak, S. E., and Glantz, M. H. (2006). Enso as an integrating concept in earth science. *Science*, 314(5806):1740–1745.
- Mielke Jr., P. W. and Johnson, E. S. (1974). Some generalized beta distributions of the second kind having desirable application features in hydrology and meteorology. *Water Resources Research*, 10(2):223–226.
- NCEP, C. P. C. . Enso: Recent evolution, current status and predictions.
- Newman, M., Compo, G. P., and Alexander, M. A. (2003). Enso-forced variability of the pacific decadal oscillation. *Journal of Climate*, 16(23):3853–3857.
- NOAA (2020). Monthly teleconnection index: North atlantic oscillation (nao).

LITERATURA CITADA

- NOAA-ESRL (2020). Noaa-esrl, “psd : Climate indices: Monthly atmospheric and ocean time series.”.
- Oglesby, R. J. (1991). Springtime soil moisture, natural climatic variability, and north american drought as simulated by the near community climate model 1. *Journal of Climate*, 4(9):890–897.
- Piechota, T. C. and Dracup, J. A. (1996). Drought and regional hydrologic variation in the united states: Associations with the el niño-southern oscillation. *Water Resources Research*, 32(5):1359–1373.
- QGIS Development Team (2009). *QGIS Geographic Information System*. Open Source Geospatial Foundation.
- R Core Team (2019). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
- Rigby, R. and Stasinopoulos, D. (1996). A semi-parametric additive model for variance heterogeneity. *Statistics and Computing*, 6(1):57–65.
- Rigby, R. A. and Stasinopoulos, D. M. (2005). Generalized additive models for location, scale and shape. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 54(3):507–554.
- Rogers, J. C. (1981). The north pacific oscillation. *Journal of Climatology*, 1(1):39–57.
- Rojas, O. (2020). Agricultural extreme drought assessment at global level using the fao-agricultural stress index system (asis). *Weather and Climate Extremes*, 27:100184. Innovations in managing climate risks and building resilience in agriculture.
- SAS Institute Inc. (2012). *SAS/STAT Software, Version 9.4*. Cary, NC.
- Schlesinger, M. E. and Ramankutty, N. (1994). An oscillation in the global climate system of period 65-70 years. *Nature*, 367(6465):723–726.
- Sharma, M. and Singh, J. (2010). Use of probability distribution in rainfall analysis. *New York Science Journal*, 3:40–49.
- Simmon, R. (2008). A summary of the path of the thermohaline circulation.
- Stacy, E. W. (1962). A generalization of the gamma distribution. *The Annals of Mathematical Statistics*, 33(3):1187–1192.
- Stagge, J. H., Tallaksen, L. M., Gudmundsson, L., Van Loon, A. F., and Stahl, K. (2015). Candidate distributions for climatological drought indices (spi and spei). *International Journal of Climatology*, 35(13):4027–4040.

LITERATURA CITADA

- Stasinopoulos, M. D., Rigby, R. A., Heller, G. Z., Voudouris, V., and Bastiani, F. D. (2017). *Flexible regression and smoothing : using GAMLSS in R*. R. Chapman and Hall/CRC.
- Stasinopoulos, M. D.; Rigby, R. A. . B. F. D. (2018). Gamlss: A distributional regression approach. *Statistical Modelling*, 18:248–273.
- Stephenson, A. G. (2002). evd: Extreme value distributions. *R News*, 2(2):0.
- Surry, A. and King, J. (2015). A new method for calculating alpi: the aleutian low pressure index. *Can. Tech. Rep. Fish. Aquat. Sci.* 3135: 31.
- Sys, C., Van Ranst, E., Debaveye, J., and Beernaert, F. (1993). Land evaluation part iii, crop requirements. *Agricultural publication*, 7.
- Tannehill, I. R. (1947). Drought, its causes and effects. *Soil Science number 1 vol 64 p83*.
- Thom, H. C. (1951). A frequency distribution for precipitation. *Bulletin of the American Meteorological Society*, 32(10):397.
- Thom, H. C. S. (1966). Some methods of climatological analysis. Technical report, World Meteorological Organization.
- Trenberth, K. E. and Hurrell, J. W. (1994). Decadal atmosphere-ocean variations in the pacific. *Climate Dynamics*, 9(6):303–319.
- Trenberth, Kevin, Z. R. (2019). The climate data guide: Atlantic multi-decadal oscillation (amo).
- van Loon, H. and Rogers, J. (1978). The seesaw in winter temperatures between greenland and northern europe. part i: General description. *Mon. Wea. Rev.*, 106, page 296–310.
- Venables, W. N. and Ripley, B. D. (2002). *Modern Applied Statistics with S*. Springer, New York, fourth edition. ISBN 0-387-95457-0.
- Walker, G. T., B. E. W. (1932). World weather v. *Mem. Roy. Meteor. Soc.*, 4, 53.
- Wallace, J. and Gutzler, D. (1981). Teleconnections in the geopotential height field during the northern hemisphere winter.
- Wallén, C. C. (1955). Some characteristics of precipitation in mexico. *Geografiska Annaler*, 37(1-2):51–85.
- Wilks, D. (1998). Multisite generalization of a daily stochastic precipitation generation model. *journal of Hydrology*, 210(1-4):178–191.
- Wood, S. N. (2006). Generalized additive models: an introduction with r. chapman and hall/crc. *Texts Stat. Sci.*, 67:391.

LITERATURA CITADA

- Woolhiser, D. A. and Roldan, J. (1982). Stochastic daily precipitation models: 2. a comparison of distributions of amounts. *Water resources research*, 18(5):1461–1468.
- Yee, T. W. (2010). The VGAM package for categorical data analysis. *Journal of Statistical Software*, 32(10):1–34.
- Yee, T. W. (2015). *Vector Generalized Linear and Additive Models: With an Implementation in R*. Springer, New York, USA.

APÉNDICE A

CÓDIGOS

A.1. Código VBA

A.1.1. Acomodo de datos originales

```
Sub Ejercicio()  
' Ejercicio Macro  
' Acceso directo: CTRL+q  
    Application.ScreenUpdating = False  
    Columns("H:H").Select  
    Selection.Delete Shift:=xlToLeft  
    Range("F:F,I:I,K:K").Select  
    Range("K1").Activate  
    Selection.Delete Shift:=xlToLeft  
    Range("J:J,L:L,N:N,P:P").Select  
    Range("P1").Activate  
    ActiveWindow.ScrollColumn = 2  
    ActiveWindow.ScrollColumn = 3  
    ActiveWindow.ScrollColumn = 4  
    ActiveWindow.ScrollColumn = 5  
    ActiveWindow.ScrollColumn = 6  
    ActiveWindow.ScrollColumn = 7  
    ActiveWindow.ScrollColumn = 8  
    ActiveWindow.ScrollColumn = 9  
    Range("J:J,L:L,N:N,P:P,R:R,T:T,V:V,X:X").Select  
    Range("X1").Activate  
    ActiveWindow.SmallScroll ToRight:=5  
    Range("J:J,L:L,N:N,P:P,R:R,T:T,V:V,X:X,Z:Z,AB:AB,AD:AD").Select  
    Range("AD1").Activate  
    Selection.Delete Shift:=xlToLeft  
    ActiveWindow.ScrollColumn = 21
```

A.1. Código VBA

```
ActiveWindow.ScrollColumn = 20
ActiveWindow.ScrollColumn = 19
ActiveWindow.ScrollColumn = 18
ActiveWindow.ScrollColumn = 17
ActiveWindow.ScrollColumn = 16
ActiveWindow.ScrollColumn = 15
ActiveWindow.ScrollColumn = 14
ActiveWindow.ScrollColumn = 13
ActiveWindow.ScrollColumn = 14
Range("U:U,W:W,Y:Y,AA:AA,AC:AC").Select
Range("AC1").Activate
ActiveWindow.SmallScroll ToRight:=12
Range("U:U,W:W,Y:Y,AA:AA,AC:AC,AE:AE,AG:AG,AI:AI,AK:AK,AM:AM,AO:AO").Select
Range("AO1").Activate
ActiveWindow.SmallScroll ToRight:=11
Range(_"U:U,W:W,Y:Y,AA:AA,AC:AC,AE:AE,AG:AG,AI:AI,
AK:AK,AM:AM,AO:AO,AQ:AQ,AS:AS,AS:AS,AU:AU,AW:AW,
AY:AY" _).Select
Range("AY1").Activate
ActiveWindow.SmallScroll ToRight:=-23
Range("U:U,W:W,Y:Y,AA:AA").Select
Range("AA1").Activate
Selection.Delete Shift:=xlToLeft
Range("Y:Y,AA:AA,AC:AC").Select
Range("AC1").Activate
ActiveWindow.SmallScroll ToRight:=11
Range("Y:Y,AA:AA,AC:AC,AE:AE,AG:AG,AI:AI,AK:AK,
AM:AM").Select
Range("AM1").Activate
Selection.Delete Shift:=xlToLeft
Range("AI:AI,AK:AK,AM:AM,AG:AG").Select
Range("AG1").Activate
Selection.Delete Shift:=xlToLeft
Range("AJ1").Select
ActiveCell.FormulaR1C1 = "PP_mensual"
Range("AJ2").Select
ActiveCell.FormulaR1C1 = "=SUM(RC[-31]:RC[-1])"
Range("AJ2").Select
Cells.Replace What:="-99999", Replacement:="na", LookAt:=xlPart, _
    SearchOrder:=xlByRows, MatchCase:=False, SearchFormat:=False, _
    ReplaceFormat:=False
Range("AJ2").Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=SUM(RC[-31]:RC[-1])"
Range("AK1").Select
```

A.1. Código VBA

```
ActiveCell.FormulaR1C1 = "Año"
Range("AL1").Select
ActiveCell.FormulaR1C1 = "Mes"
Range("AK2").Select
ActiveCell.FormulaR1C1 = "=MID(RC[-33],1,4)"
Range("AK2").Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=MID(RC[-33],1,4)"
ActiveWindow.SmallScroll Down:=-1
Range("AL2").Select
ActiveCell.FormulaR1C1 = "=MID(RC[-34],5,2)"
Range("AL2").Select
ActiveCell.FormulaR1C1 = "=MID(RC[-34],6,2)"
Range("AL2").Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=MID(RC[-34],6,2)"
Range("AM1").Select
ActiveCell.FormulaR1C1 = "Bisiesto"
Range("AM2").Select
ActiveCell.FormulaR1C1 = "=IF(RC[-2]/4=INT(RC[-2]/4),""T"", ""F"")"
Range("AM2").Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=IF(RC[-2]/4=INT(RC[-2]/4),""T"", ""F"")"
ActiveWindow.ScrollRow = 1
Range("AN1").Select
ActiveCell.FormulaR1C1 = "Contar_na"
Range("AN2").Select
ActiveSheet.Paste
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = _
    "=IF(RC[-2]=""02"", IF(RC[-1]=""F"", COUNTIF(RC[-35]:RC[-8], ""na""), COUNTIF(RC
'Range("AN1").Select
Range("AN1").Select
ActiveCell.FormulaR1C1 = "Contar_na"
Range("AN2").Select
'ActiveSheet.Paste
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = _
    "=IF(RC[-2]=""02"", IF(RC[-1]=""F"",
    COUNTIF(RC[-35]:RC[-8], ""na""),
    COUNTIF(RC[-35]:RC[-7], ""na"")),
    IF(OR(RC[-2]=""04"", RC[-2]=""06"", RC[-2]=""09"",
```

A.1. Código VBA

```
RC[-2]="11"),COUNTIF(RC[-35]:RC[-6],"na"),
COUNTIF(RC[-35]:RC[-5],"na"))"
Range("A01").Select
ActiveCell.FormulaR1C1 = "Min_mensual"
Range("A02").Select
'ActiveSheet.Paste
ActiveCell.FormulaR1C1 = "=MIN(RC[-36]:RC[-6])"
Range("A02").Select
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=MIN(RC[-36]:RC[-6])"
Range("AP1").Select
ActiveCell.FormulaR1C1 = "Max_mensual"
Range("AP2").Select
ActiveCell.FormulaR1C1 = "=MAX(RC[-37]:RC[-7])"
Range("AP2").Select
Range(Selection, Selection.End(xlDown)).Select
Selection.FormulaR1C1 = "=MAX(RC[-37]:RC[-7])"
Range("AP1").Select
'Range("AN1").Select
Selection.End(xlToLeft).Select
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlDown)).Select
Range(Selection, Selection.End(xlToRight)).Select
Sheets.Add After:=ActiveSheet
ActiveWorkbook.PivotCaches.Create(
SourceTypes:=xlDatabase, SourceData:= _
"R1C1:R1048576C40", Version:=6).CreatePivotTable TableDestination:= _
"Hoja1!R3C1", TableName:="TablaDinámica1", DefaultVersion:=6
Sheets("Hoja1").Select
Cells(3, 1).Select
With ActiveSheet.PivotTables("TablaDinámica1")
.ColumnGrand = True
.HasAutoFormat = True
.DisplayErrorString = False
.DisplayNullString = True
.EnableDrilldown = True
.ErrorString = ""
.MergeLabels = False
.NullString = "na"
.PageFieldOrder = 2
.PageFieldWrapCount = 0
.PreserveFormatting = True
.RowGrand = True
.SaveData = True
```

A.1. Código VBA

```
.PrintTitles = False
.RepeatItemsOnEachPrintedPage = True
.TotalsAnnotation = False
.CompactRowIndent = 1
.InGridDropZones = False
.DisplayFieldCaptions = True
.DisplayMemberPropertyTooltips = False
.DisplayContextTooltips = True
.ShowDrillIndicators = True
.PrintDrillIndicators = False
.AllowMultipleFilters = False
.SortUsingCustomLists = True
.FieldListSortAscending = False
.ShowValuesRow = False
.CalculatedMembersInFilters = False
.RowAxisLayout xlCompactRow
End With
With ActiveSheet.PivotTables("TablaDinámica1").PivotCache
.RefreshOnFileOpen = False
.MissingItemsLimit = xlMissingItemsDefault
End With
ActiveSheet.PivotTables("TablaDinámica1").RepeatAllLabels xlRepeatLabels
With ActiveSheet.PivotTables("TablaDinámica1").
PivotFields("ELEMENT-CODE")
.Orientation = xlPageField
.Position = 1
End With
ActiveSheet.PivotTables("TablaDinámica1").
AddDataField ActiveSheet.PivotTables( _
"TablaDinámica1").PivotFields("PP_mensual"),
"Suma de PP_mensual", xlSum
With ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("Mes")
.Orientation = xlColumnField
.Position = 1
End With
With ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("Año")
.Orientation = xlRowField
.Position = 1
End With
With ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("Station-ID")
.Orientation = xlRowField
.Position = 1
```

A.1. Código VBA

```
End With
ActiveWindow.ScrollColumn = 2
ActiveWindow.ScrollColumn = 3
ActiveWindow.ScrollColumn = 4
ActiveWindow.ScrollColumn = 5
ActiveWindow.ScrollColumn = 6
ActiveWindow.ScrollColumn = 5
ActiveWindow.ScrollColumn = 4
ActiveWindow.ScrollColumn = 3
ActiveWindow.ScrollColumn = 2
ActiveWindow.ScrollColumn = 1
ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("ELEMENT-CODE"). _
    ClearAllFilters
ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("ELEMENT-CODE"). _
    CurrentPage = "5"
Application.ScreenUpdating = True
End Sub
```

A.1.2. Obtención de valores únicos

```
Sub GetUniqueValues()
,
' GetUniqueValues Macro
,
' Acceso directo: CTRL+w
,
Application.ScreenUpdating = False
Dim data As Variant, temp As Variant
Dim obj As Object
Dim i As Long
Dim pi As PivotItem
Set obj = CreateObject("scripting.dictionary")
Worksheets(1).Activate
Range("B2").Select
Range(Selection, Selection.End(xlDown)).Select
data = Selection
For i = 1 To UBound(data)
    obj(data(i, 1) & "") = ""
Next
temp = obj.keys
j = obj.Count - 1
Worksheets(2).Activate
'cat = CStr(temp(j))
```

A.1. Código VBA

```
'With ActiveSheet.PivotTables("TablaDinámica1")
.PivotFields("Station-ID")
'    .Orientation = xlPageField
'    .Position = 1
'    .ClearAllFilters
'    .CurrentPage = cat
' End With
For i = 0 To j
    cat = CStr(temp(i))
    With ActiveSheet.PivotTables("TablaDinámica1")
        .PivotFields("Station-ID")
            .Orientation = xlPageField
            .Position = 1
            .ClearAllFilters
            .CurrentPage = cat
    End With
    Range("A5").Select
    Range("A5:AA5").Select
    Range(Selection, Selection.End(xlDown)).Select
    Selection.Copy
    'Sheets.Add After:=ThisWorkbook.Sheets(.Sheets.Count)
    Sheets.Add(After:=ActiveWorkbook
        .Sheets(ActiveWorkbook.Sheets.Count))
        .Name = cat
    Worksheets(ActiveWorkbook.Sheets.Count).Activate
    Range("A1").Select
    ActiveCell.FormulaR1C1 = "Año"
    Range("B1").Select
    ActiveCell.FormulaR1C1 = "PP_Ene"
    Range("C1").Select
    ActiveCell.FormulaR1C1 = "PP_Feb"
    Range("D1").Select
    ActiveCell.FormulaR1C1 = "PP_Mar"
    Range("E1").Select
    ActiveCell.FormulaR1C1 = "PP_Abr"
    Range("F1").Select
    ActiveCell.FormulaR1C1 = "PP_May"
    Range("G1").Select
    ActiveCell.FormulaR1C1 = "PP_Jun"
    Range("H1").Select
    ActiveCell.FormulaR1C1 = "PP_Jul"
    Range("I1").Select
    ActiveCell.FormulaR1C1 = "PP_Ago"
    Range("J1").Select
    ActiveCell.FormulaR1C1 = "PP_Sep"
```

A.1. Código VBA

```
Range("K1").Select
ActiveCell.FormulaR1C1 = "PP_Oct"
Range("L1").Select
ActiveCell.FormulaR1C1 = "PP_Nov"
Range("M1").Select
ActiveCell.FormulaR1C1 = "PP_Dic"
Range("N1").Select
ActiveCell.FormulaR1C1 = "PP_Anual"
Range("A2").Select
'Sheets("Hoja6").Select
Selection.PasteSpecial Paste:=xlPasteValues,
    Operation:=xlNone, SkipBlanks _
        :=False, Transpose:=False
Selection.End(xlDown).Select
Range(Selection, Selection.End(xlToRight)).Select
Application.CutCopyMode = False
Selection.ClearContents
Range("O1").Select
ActiveCell.FormulaR1C1 = "Est"
Range("O2").Select
ActiveCell.FormulaR1C1 = cat
Range("P1").Select
ActiveCell.FormulaR1C1 = "PP_Ene"
Range("Q1").Select
ActiveCell.FormulaR1C1 = "PP_Feb"
Range("R1").Select
ActiveCell.FormulaR1C1 = "PP_Mar"
Range("S1").Select
ActiveCell.FormulaR1C1 = "PP_Abr"
Range("T1").Select
ActiveCell.FormulaR1C1 = "PP_May"
Range("U1").Select
ActiveCell.FormulaR1C1 = "PP_Jun"
Range("V1").Select
ActiveCell.FormulaR1C1 = "PP_Jul"
Range("W1").Select
ActiveCell.FormulaR1C1 = "PP_Ago"
Range("X1").Select
ActiveCell.FormulaR1C1 = "PP_Sep"
Range("Y1").Select
ActiveCell.FormulaR1C1 = "PP_Oct"
Range("Z1").Select
ActiveCell.FormulaR1C1 = "PP_Nov"
Range("AA1").Select
ActiveCell.FormulaR1C1 = "PP_Dic"
```


A.1. Código VBA

```
Range("P2").Select
ActiveWindow.ScrollColumn = 10
ActiveWindow.ScrollColumn = 9
ActiveWindow.ScrollColumn = 8
ActiveWindow.ScrollColumn = 7
ActiveWindow.ScrollColumn = 6
ActiveWindow.ScrollColumn = 5
ActiveWindow.ScrollColumn = 4
ActiveWindow.ScrollColumn = 3
ActiveWindow.ScrollColumn = 2
ActiveWindow.ScrollColumn = 3
Selection.FormulaR1C1 = "=AVERAGE(RC[-14]:R[1048574]C[-14])"
ActiveCell.SpecialCells(xlLastCell).Select
Selection.End(xlUp).Select
Range("P2").Select
Selection.AutoFill Destination:=Range("P2:AA2"),
    Type:=xlFillDefault
Range("P2:AA2").Select
Range("AC1").Select
ActiveCell.FormulaR1C1 = "Counts_años"
Range("AC2").Select
ActiveCell.FormulaR1C1 = "=1048576-COUNTBLANK(C[-28])"
Range("AC2").Select
ActiveCell.FormulaR1C1 = "=1048576-COUNTBLANK(C[-28])-2"
Range("AC2").Select
Sheets(2).Select
Next
Application.ScreenUpdating = True
End Sub
Sub Est()
,
' Est Macro
,
' Acceso directo: CTRL+s
,
Application.ScreenUpdating = False
Sheets.Add(After:=ActiveWorkbook.Sheets(ActiveWorkbook.Sheets.Count)).Name = "Est"
j = ActiveWorkbook.Sheets.Count - 1

For i = 3 To j
Worksheets(i).Activate
Range("O2:AC2").Select
Selection.Copy
Worksheets(j + 1).Activate
```

A.1. Código VBA

```
Cells(i - 1, 1).Select
Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
    :=False, Transpose:=False
    Range("A1").Select
    ActiveCell.FormulaR1C1 = "Est"
    Range("B1").Select
    ActiveCell.FormulaR1C1 = "PP_Ene"
    Range("C1").Select
    ActiveCell.FormulaR1C1 = "PP_Feb"
    Range("D1").Select
    ActiveCell.FormulaR1C1 = "PP_Mar"
    Range("E1").Select
    ActiveCell.FormulaR1C1 = "PP_Abr"
    Range("F1").Select
    ActiveCell.FormulaR1C1 = "PP_May"
    Range("G1").Select
    ActiveCell.FormulaR1C1 = "PP_Jun"
    Range("H1").Select
    ActiveCell.FormulaR1C1 = "PP_Jul"
    Range("I1").Select
    ActiveCell.FormulaR1C1 = "PP_Ago"
    Range("J1").Select
    ActiveCell.FormulaR1C1 = "PP_Sep"
    Range("K1").Select
    ActiveCell.FormulaR1C1 = "PP_Oct"
    Range("L1").Select
    ActiveCell.FormulaR1C1 = "PP_Nov"
    Range("M1").Select
    ActiveCell.FormulaR1C1 = "PP_Dic"
    Range("N1").Select
    ActiveCell.FormulaR1C1 = "PP_Anual"
    Range("O1").Select
    ActiveCell.FormulaR1C1 = "Count_años"
    Range("N2").Select
    ActiveCell.FormulaR1C1 = "=SUM(RC[-12]:RC[-1])"
    Range("N2").Select
    Range(Selection, Selection.End(xlDown)).Select
    Selection.FormulaR1C1 = "=SUM(RC[-12]:RC[-1])"
Next
Application.ScreenUpdating = True
End Sub

Public ultimaFila As Long
Public ultimaColumna As Long
```

A.1. Código VBA

'obtener datos del cuestionario base

```
Sub ultimaFila1(ncolu As Integer) 'Identifica la última fila que contiene
datos en la columna ncolu
    ultimaFila = Cells(Cells.Rows.Count, ncolu).End(xlUp).Row
    'MsgBox ultimaFila
End Sub
```

```
Sub ultimaColumn(nfila As Integer) 'Identifica la última columna que
contiene datos en la fila nfila
    ultimaColumna = Cells(nfila, Cells.Columns.Count).End(xlToLeft).
Column
    'MsgBox ultimaColumna
End Sub
```

```
Sub Numbner()
,
' Number Macro
,
j = ActiveWorkbook.Sheets.Count
For i = 2 To j
Worksheets(i).Activate
Range("A2").Select
Range(Selection, Selection.End(xlDown)).Select
    For Each xCell In Selection
        xCell.Value = CDBl(xCell.Value)
    Next xCell
Next
End Sub
```

A.1.3. Obtención de los valores de NA

```
Sub NApencent()
Dim Ene As Range
Dim Feb As Range
Dim Mar As Range
Dim Abr As Range
Dim May As Range
Dim Jun As Range
Dim Jul As Range
Dim Ago As Range
Dim Sep As Range
Dim Oct As Range
Dim Nov As Range
Dim Dic As Range
j = ActiveWorkbook.Sheets.Count
```

A.1. Código VBA

```
For i = 2 To j
    Worksheets(i).Activate
    Set Ene = ActiveSheet.Range("B:B")
    Set Feb = ActiveSheet.Range("C:C")
    Set Mar = ActiveSheet.Range("D:D")
    Set Abr = ActiveSheet.Range("E:E")
    Set May = ActiveSheet.Range("F:F")
    Set Jun = ActiveSheet.Range("G:G")
    Set Jul = ActiveSheet.Range("H:H")
    Set Ago = ActiveSheet.Range("I:I")
    Set Sep = ActiveSheet.Range("J:J")
    Set Oct = ActiveSheet.Range("K:K")
    Set Nov = ActiveSheet.Range("L:L")
    Set Dic = ActiveSheet.Range("M:M")
    Call ultimaFila1(1)
    'MsgBox (ultimaFila - 1) / (ultimaFila - 1)
    Ene1 = (CStr(Application.WorksheetFunction.Count(Ene))
    / (ultimaFila - 1)) * 100
    Feb1 = (CStr(Application.WorksheetFunction.Count(Feb))
    / (ultimaFila - 1)) * 100
    Mar1 = (CStr(Application.WorksheetFunction.Count(Mar))
    / (ultimaFila - 1)) * 100
    Abr1 = (CStr(Application.WorksheetFunction.Count(Abr))
    / (ultimaFila - 1)) * 100
    May1 = (CStr(Application.WorksheetFunction.Count(May))
    / (ultimaFila - 1)) * 100
    Jun1 = (CStr(Application.WorksheetFunction.Count(Jun))
    / (ultimaFila - 1)) * 100
    Jul1 = (CStr(Application.WorksheetFunction.Count(Jul))
    / (ultimaFila - 1)) * 100
    Ago1 = (CStr(Application.WorksheetFunction.Count(Ago))
    / (ultimaFila - 1)) * 100
    Sep1 = (CStr(Application.WorksheetFunction.Count(Sep))
    / (ultimaFila - 1)) * 100
    Oct1 = (CStr(Application.WorksheetFunction.Count(Oct))
    / (ultimaFila - 1)) * 100
    Nov1 = (CStr(Application.WorksheetFunction.Count(Nov))
    / (ultimaFila - 1)) * 100
    Dic1 = (CStr(Application.WorksheetFunction.Count(Dic))
    / (ultimaFila - 1)) * 100
    Ene2 = (100 - Ene1)
    Feb2 = (100 - Feb1)
    Mar2 = (100 - Mar1)
    Abr2 = (100 - Abr1)
    May2 = (100 - May1)
```

A.1. Código VBA

```
Jun2 = (100 - Jun1)
Jul2 = (100 - Jul1)
Ago2 = (100 - Ago1)
Sep2 = (100 - Sep1)
Oct2 = (100 - Oct1)
Nov2 = (100 - Nov1)
Dic2 = (100 - Dic1)
Range("O1").Activate
ActiveCell.FormulaR1C1 = "Mes"
Range("P1").Activate
ActiveCell.FormulaR1C1 = "%"
Range("O2").Activate
ActiveCell.FormulaR1C1 = "Ene"
ActiveCell.Offset(0, 1).Value2 = Ene2
ActiveCell.Offset(1, 0).FormulaR1C1 = "Feb"
ActiveCell.Offset(1, 1).Value2 = Feb2
ActiveCell.Offset(2, 0).FormulaR1C1 = "Mar"
ActiveCell.Offset(2, 1).Value2 = Mar2
ActiveCell.Offset(3, 0).FormulaR1C1 = "Abr"
ActiveCell.Offset(3, 1).Value2 = Abr2
ActiveCell.Offset(4, 0).FormulaR1C1 = "May"
ActiveCell.Offset(4, 1).Value2 = May2
ActiveCell.Offset(5, 0).FormulaR1C1 = "Jun"
ActiveCell.Offset(5, 1).Value2 = Jun2
ActiveCell.Offset(6, 0).FormulaR1C1 = "Jul"
ActiveCell.Offset(6, 1).Value2 = Jul2
ActiveCell.Offset(7, 0).FormulaR1C1 = "Ago"
ActiveCell.Offset(7, 1).Value2 = Ago2
ActiveCell.Offset(8, 0).FormulaR1C1 = "Sep"
ActiveCell.Offset(8, 1).Value2 = Sep2
ActiveCell.Offset(9, 0).FormulaR1C1 = "Oct"
ActiveCell.Offset(9, 1).Value2 = Oct2
ActiveCell.Offset(10, 0).FormulaR1C1 = "Nov"
ActiveCell.Offset(10, 1).Value2 = Nov2
ActiveCell.Offset(11, 0).FormulaR1C1 = "Dic"
ActiveCell.Offset(11, 1).Value2 = Dic2
Next
End Sub
```

A.1.4. Obtención de los datos analizados

```
Public ultimaFila As Long
Public ultimaColumna As Long
'obtener datos del cuestionario base
Sub ultimaFila1(ncolu As Integer) 'Identifica la última fila que
```

A.1. Código VBA

```
contiene datos en la columna ncolu
    ultimaFila = Cells(Cells.Rows.Count, ncolu).End(xlUp).Row
    'MsgBox ultimaFila
End Sub
Sub buscaarchivos()
    ruta = obtenercarpeta
    If ruta = "" Then Exit Sub
    Range("h5").Activate
    Mostrar_Archivos (ruta)
End Sub
Sub importardatos()
Dim origen As Workbook
Dim hojao As Worksheet
Dim destino As Workbook
Dim hojad As Worksheet
Dim ruta As Variant
Dim r() As Variant
Dim pesp() As Variant
Dim pgen() As Variant
Dim naIMOPS() As Variant
Dim rg As Range
Dim dpe As Variant
Dim dpj As Variant
Dim search As String
Dim rgsearch As Range
Dim destpesp As Worksheet
Dim destcot As Worksheet
Dim pwdl As String
Dim estaciones As Variant
Dim buscar As String
nrow = Selection.Rows.Count 'Número de
    cotizaciones, contratistas
estaciones = Range("j2:j605").Value2
MsgBox estaciones(2, 1)
nestaciones = UBound(estaciones)
ReDim Preserve r(1 To nrow, 1 To 1)
r = Selection.Value2
'estaciones=array(
Set destino = Workbooks(ThisWorkbook.Name)
'ActiveSheet.Name = "C_" & naIMOPS(k)
For j = 1 To nrow 'lee los cuestionarios
    ruta = r(j, 1)
    Set origen = Workbooks.Open(ruta)
    nhojas = origen.Worksheets.Count
```

A.1. Código VBA

```
For k = 1 To hojas
    buscar = origen.Sheets(k).Name
    For l = 1 To nestaciones
        If buscar = CStr(estaciones(l, 1)) Then
            origen.Sheets(k).Copy After:=destino.Sheets
            (destino.Sheets.Count)
            Exit For
        Else
            End If
    Next l
Next k
origen.Close savechanges:=False 'cierre del archivo
Next
End Sub
Sub Count()
j = ActiveWorkbook.Sheets.Count - 4
MsgBox j
End Sub
Sub Estnames()
j = ActiveWorkbook.Sheets.Count - 2
'Erase EstNom
l = 0
For i = 3 To j
Worksheets(i).Activate
l = l + 1
ReDim Preserve EstNom(1 To l)
EstNom(l) = ActiveSheet.Name
Next
End Sub
Sub Expnam()
Sheets.Add(After:=ActiveWorkbook.
Sheets(ActiveWorkbook.Sheets.Count)).
Name = "Est_filter"
ActiveSheet.Range(Cells(1, 1),
Cells(UBound(EstNom), 1)).Value2 = Application.WorksheetFunction.
Transpose(EstNom)
End Sub
```

A.2. Códigos SAS

A.2. Códigos SAS

A.2.1. Distribución de los datos de precipitación por estación

```
proc import datafile="D:\Ejemplo\ZAC32001.xls" dbms=xls replace
out=work.testing;
sheet=Hoja1;
run;
proc contents data = work.testing
out = varsbook(keep = varnum name)
noprint;
run;
proc print data=varsbook;
run;
proc sql noprint;
select distinct name
into :orderedvars separated by ' '
from varsbook
order by varnum;
quit;
proc sql noprint;
select max(varnum)-1
into :mvar
from varsbook
quit;
%put &mvar;
%macro ajuste;
%do i=1 %to &mvar;
%let probando=%substr(&orderedvars,5+(&i-1)*9,8);
proc severity data=work.testing crit=aicc;
loss &probando;
dist _predefined_;
ods output ModelSelection=&probando;
ods output ParameterEstimates=EST&probando;
quit;
run;
proc sql noprint;
select _MODEL_
into :modelsel
from &probando
where Selected="Sí"
;
quit;
proc sql noprint;
create table parse1 as
```


A.2. Códigos SAS

```
select *
from Est&probando
where _MODEL_ = "&modelsel"
;
quit;
data parsel;
set parsel;
datos="&probando";
run;
proc append base=finald data=parsel;
run;
%end;
%mend ajuste;
%ajuste
proc export data=work.finald
outfile="D:\Resultados\ZAC.xls" dbms=xls;
run;
proc import datafile="D:\Ejemplomin\CHI8001.xls" dbms=xls
out=work.testing;
sheet=Hojal;
run;
proc contents data = work.testing
out = varsbook(keep = varnum name)
noprint;
run;
proc print data=varsbook;
run;
proc sql noprint;
select distinct name
into :orderedvars separated by ' '
from varsbook
order by varnum;
quit;
proc sql noprint;
select max(varnum)-1
into :mvar
from varsbook
quit;
%put &mvar;
%macro ajuste;
%do i=1 %to &mvar;
%let probando=%substr(&orderedvars,5+(&i-1)*8,7);
proc severity data=work.testing crit=aicc;
loss &probando;
```

A.2. Códigos SAS

```
dist _predefined_;
ods output ModelSelection=&probando;
ods output ParameterEstimates=EST&probando;
quit;
run;
proc sql noprint;
select _MODEL_
into :modelsel
from &probando
where Selected="Sí"
;
quit;
proc sql noprint;
create table parse1 as
select *
from Est&probando
where _MODEL_ = "&modelsel"
;
quit;
data parse1;
set parse1;
datos="&probando";
run;
proc append base=finald data=parse1;
run;
%end;
%mend ajuste;
%ajuste
proc export data=work.finald
outfile="D:\Resultados min\CHImin.xls" dbms=xls;
run;
```

A.3. Códigos R

A.3. Códigos R

A.3.1. Selección de las distribuciones

```
#paquetes
#install.packages(c("ggplot2", "tibble", "tidyr","stringr", "forcats",
#                  "readr", "rlang", "purrr", "dplyr", "tidyverse", "fs",
#                  "readxl", "rlang", "GB2", "gamlss", "VGAM"))
library(MASS)
library(ggplot2)
library(tibble)
library(tidyr)
library(stringr)
library(forcats)
library(readr)
library(rlang)
library(purrr)
library(dplyr)
library(tidyverse)
library(fs)
library(readxl)
library(rlang)
library(GB2)
library(gamlss)
library(VGAM)
library(rmutil)
#setwd("C:/ResultsR")

dgb2p<-function(x,theta=c(a,b,c,d,pp))
{ ifelse (x==0,theta[5],(1-theta[5])*dgb2(x,theta[1],theta[2],theta[3],
theta[4]))}

pgb2p<-function(x,theta=c(a,b,c,d,pp))
{ ifelse (x==0,theta[5],(1-theta[5])*pgb2(x,theta[1],theta[2],theta[3],
theta[4])+theta[5])}

dgamma2<-function(x,theta=c(a,b,pp))
{ ifelse (x==0,theta[3],(1-theta[3])*dgamma(x,theta[1],theta[2]))}

pgamma2<-function(x,theta=c(a,b,pp))
{ ifelse (x==0,theta[3],(1-theta[3])*pgamma(x,theta[1],theta[2])+theta[3])}

dggamma2<-function(x,theta=c(a,b,c,pp))
{ ifelse (x==0,theta[4],(1-theta[4])*dggamma(x,theta[1],theta[2],theta[3],
theta[4]))}
```

A.3. Códigos R

```
pggamma2<-function(x,theta=c(a,b,c,pp))
{ ifelse (x==0,theta[4],(1-theta[4])*pgengamma.stacy(x,theta[1],theta[2],
theta[3])+theta[4])}

path <- paste("C:/Data/Est_mon.xlsm")

#For para los datos
#str(twt)
twt<-path %>% excel_sheets()
twt<-twt[-1]
#twt<-twt[-1]
z<-length(twt)

twt[i]

PP_Anual=c("PP_Ene", "PP_Feb", "PP_Mar", "PP_Abr", "PP_May", "PP_Jun", "PP_Jul",
"PP_Ago", "PP_Sep", "PP_Oct", "PP_Nov", "PP_Dic")
Month=c("Ene","Feb","Mar","Abr","May","Jun","Jul",
"Ago","Sep","Oct","Nov","Dic")
data<- read_excel(paste("C:/Data/Est_mon.xlsm"),
sheet = (i+1), range=cell_cols(1:13))
A=c(data$Año)
PP_Ene<- c(data$PP_Ene)
PP_Feb<- c(data$PP_Feb)
PP_Mar<- c(data$PP_Mar)
PP_Abr<- c(data$PP_Abr)
PP_May<- c(data$PP_May)
PP_Jun<- c(data$PP_Jun)
PP_Jul<- c(data$PP_Jul)
PP_Ago<- c(data$PP_Ago)
PP_Sep<- c(data$PP_Sep)
PP_Oct<- c(data$PP_Oct)
PP_Nov<- c(data$PP_Nov)
PP_Dic<- c(data$PP_Dic)

## ajuste de la GB2 parametros año

for(w in 5:10){
  #w=5
  eval(parse(text=paste("PP_",Month[w], "<-na.omit(PP_",
  Month[w],")", sep="")))
  eval(parse(text=paste("nozero",Month[w], "<-ifelse(PP_",
Month[w], ">0,1,0)", sep="")))
  eval(parse(text=paste(Month[w], "_pp<-data.frame(",PP_Anual[w],
```

A.3. Códigos R

```
",nozero",Month[w],")",sep=""))
eval(parse(text=paste("zero",Month[w], "<-
length(nozero",Month[w],")-
sum(nozero",Month[w],")",sep=""))))
eval(parse(text=paste("p",Month[w], "<-zero",
Month[w],"/length(nozero",Month[w],")",
sep=""))))

## Truncate at 0
try(eval(parse(text=paste(PP_Anual[w], "1 <-",Month[w], "_pp$",
PP_Anual[w], "[",Month[w], "_pp$",PP_Anual[w], " > 0]",sep=""))))
try(eval(parse(text=paste("nozero",Month[w], "1<-",Month[w], "_pp$nozero",Month[w],
"[",Month[w], "_pp$",PP_Anual[w], ">0]",sep=""))))
try(eval(parse(text=paste(Month[w], "<- mlfit.gb2(",PP_Anual[w],
"1,nozero",Month[w], "1)",sep="")))) #dgb2
try(eval(parse(text=paste("af",Month[w], "<-", Month[w], "[[2]]$par[1]",
sep=""))))
try(eval(parse(text=paste("bf",Month[w], "<-", Month[w],
"[[2]]$par[2]",sep=""))))
try(eval(parse(text=paste("pf",Month[w], "<-", Month[w],
"[[2]]$par[3]",sep=""))))
try(eval(parse(text=paste("qf",Month[w], "<-",
Month[w], "[[2]]$par[4]",sep=""))))
}

#Gamma
for (w in 5 : 10) {
  ##Ajuste con variables
  ###Nothing

try(eval(parse(text=paste("gamma",Month[w], "0<-glm(PP_",Month[w],
"1~1,family = Gamma(link = 'inverse')",sep=""))))
try(eval(parse(text=paste("AICgamma",Month[w],
"0=AIC(gamma",Month[w], "0)",sep=""))))
try(eval(parse(text=paste("theta",Month[w],
"1", "<-gamma",Month[w], "0$coefficients",sep=""))))
if(eval(parse(text=paste("length(theta",Month[w], "1)==1",sep="")))){
eval(parse(text=paste("a",Month[w], "=(theta",Month[w], "1)",sep=""))))
eval(parse(text=paste("b",Month[w], "=1",sep=""))))
eval(parse(text=paste("theta",Month[w], "1", "<-c(a",Month[w], ", b",Month[w],
",p",Month[w],")",sep=""))))
}

}

#VGLM GEV
```

A.3. Códigos R

```
for (w in 1:12){
try(eval(parse(text=paste(Month[w], "GEV0=vglm(PP_", Month[w], "
~ 1, gevff( ), data = list(PP_", Month[w], "), trace=T)", sep="")))

for(j in c(1:12)){
if(exists(paste(Month[w], "GEV0", sep = ""))){
try(eval(parse(text=paste("AICGEV", Month[w], "0=AICvlm(", Month[w], "GEV0)", sep="")))
try(eval(parse(text=paste("CoefGEV", Month[w], "0=Coef(", Month[w], "GEV0)", sep="")))
} else {eval(parse(text=paste("AICGEV", Month[w], "0=NaN", sep="")))
eval(parse(text=paste("CoefGEV", Month[w], "0=NaN", sep="")))
}
}
}

#Gamma Generalizada
for (w in 5 : 10) {
  ##Ajuste con variables
  ###Nothing
try(eval(parse(text=paste("gamma", Month[w], "0<-glm(PP_", Month[w], "1~1,
family = Gamma(link = 'inverse')", sep="")))
try(eval(parse(text=paste("AICgamma", Month[w], "0=AIC(
gamma", Month[w], "0)", sep="")))
try(eval(parse(text=paste("theta", Month[w], "1", "<-
gamma", Month[w], "0$coefficients", sep="")))
if(eval(parse(text=paste("length(theta", Month[w],
"1)==1", sep=""))) {
eval(parse(text=paste("a", Month[w], "= (theta",
Month[w], "1)", sep="")))
eval(parse(text=paste("b", Month[w], "= 1", sep="")))
eval(parse(text=paste("theta", Month[w], "1", "<-
c(a", Month[w], ", b", Month[w], ", p", Month[w], ")", sep="")))
}

}

#VGLM GG
for (w in 5:10){
try(eval(parse(text=paste(Month[w], "GG0=vglm(PP_", Month[w], "1
~ 1, gengamma.stacy( ), data = list(PP_",
Month[w], ")", trace=T)", sep="")))

for(j in c(1:12)){
if(exists(paste(Month[w], "GG0", sep = ""))){
try(eval(parse(text=paste("AICGG", Month[w], "0=AICvlm(", Month[w], "GG0)", sep="")))
try(eval(parse(text=paste("CoefGG", Month[w], "0=Coef(", Month[w], "GG0)", sep="")))
} else {eval(parse(text=paste("AICGG", Month[w], "0=NaN", sep="")))
}
```

A.3. Códigos R

```
eval(parse(text=paste("CoefGG",Month[w],"0=NaN",sep="")))
}
}
#Graficar los ecdf
setwd("C:/ResultsR/ECDF")
jpeg("simbología.jpg",width = 1920,height = 1080)
par(mfrow=c(1,1))
plot(x=0)
legend(1,1, c('GB2',"GEV", "GA","GG"),col=c("black", "cornflowerblue",
"green4","deeppink"),lwd=c(2,2,2,2), lty=c(1,1,1,2))
dev.off()
jpeg(paste("ECDF",twt[i],".jpg", sep = ""),width = 1080,height = 1080)
par(mfrow=c(3,2))
for (w in 5:10){
eval(parse(text=paste("PP_",Month[w],"<-sort(PP_",Month[w],")",sep="")))
eval(parse(text=paste("PP_",Month[w],"1<-sort(PP_",Month[w],")", sep="")))
eval(parse(text=paste("theta",Month[w], "=c(af",
Month[w],",bf",Month[w],",pf",Month[w],",qf",
Month[w],",p",Month[w],")",sep="")))
eval(parse(text=paste("theta",Month[w], "2=c(Coef(",
Month[w], "GG0)[1], Coef(",Month[w], "GG0)[2],
Coef(",Month[w], "GG0)[3],p",Month[w],")",
sep="")))
eval(parse(text=paste(Month[w], "a<-pgb2p(PP_",Month[w],
",theta",Month[w],")",sep="")))
eval(parse(text=paste(Month[w], "b<-pgev(PP_",
Month[w],",location=Coef(",Month[w]
,"GEV0)[1], scale=Coef(",Month[w], "GEV0)[2], shape=Coef(",Month[w]
,"GEV0)[3])", sep="")))
eval(parse(text=paste(Month[w], "c=pgamma2(PP_"
,Month[w],",theta",Month[w],")",sep="")))
eval(parse(text=paste(Month[w], "d=pggamma2(PP_"
,Month[w],",theta",Month[w],")",sep="")))
eval(parse(text=paste("Plot",Month[w],
"=plot(ecdf(PP_",Month[w],"), main=' ",Month[w],"',
col='gray50')", sep="")))
eval(parse(text=paste("lines(PP_",Month[w],",",
,Month[w],",a,add=T, col='black', lwd=2)", sep="")))
eval(parse(text=paste("lines(PP_",Month[w],",",
,Month[w],",b, add=T,col='cornflowerblue', lwd=2)",sep="")))
eval(parse(text=paste("lines(PP_",Month[w],",",
,Month[w],",c, add=T, col='green3', lwd=2)", sep="")))
eval(parse(text=paste("lines(PP_",Month[w],",",
,Month[w],",d, add=T,col='deeppink', lwd=4,lty=3)", sep="")))
}
```

A.3. Códigos R

```
mtext(paste("ECDFEst", twt[i]), side=3, outer=T, line = -1.5)
dev.off()
```

A.3.2. Cálculo de ETC del cultivo del frijol

```
inilluvias=read.csv("C:/ResultsR/Results/Resultsa.csv")
#15+20
Mon=c("E", "F", "M", "A", "MY", "J", "JL", "AG", "S", "O", "N", "D")
Mond=c(31, 28, 31, 30, 31, 30, 31, 31, 30, 31, 30, 31)
```

```
head(inilluvias)
```

```
Est_cl=inilluvias$CLAVE
ini=inilluvias$ini
des=inilluvias$des
mid=inilluvias$mid
end=inilluvias$fin
```

```
ETPMY=inilluvias$ETP_MY
ETPJ=inilluvias$ETP_J
ETPJL=inilluvias$ETP_JL
ETPAG=inilluvias$ETP_AG
ETPS=inilluvias$ETP_S
ETPO=inilluvias$ETP_0
```

```
kini=inilluvias$kini
kmid=inilluvias$kmid
kend=inilluvias$kend
```

```
winim=ini+15-Mond[5]
```

```
#iniciomay
a=15
month_a=5
ETC_MY=(ETPMY*a)*kini
ETC_J1=ETPJ*b1*kini
```

```
b1=winim[1]
month_b1=6
wdes=des+b1-Mond[6]
ETC_J2=ETPJ*(Mond[6]-b1)*kini
ETC_J=ETC_J1+ETC_J2
```

```
ETC_JL1=ETPJL*b2*kini
```


A.3. Códigos R

```
b2=wdes[1]
month_b2=7
wmid=mid+b2-Mond[7]
ETC_Jl2=ETPjL*(Mond[7]-b2)*kmid
ETC_Jl=ETC_Jl1+ETC_Jl2
ETC_AG1=ETPAG*c*kmid

c=wmid[1]
month_c=8
wend=end+c-Mond[8]
ETC_AG2=ETPAG*(Mond[8]-c)*kend
ETC_AG=ETC_AG1+ETC_AG2

e=wend[1]
month_end=9
ETC_S=ETPS*c*kend
ETC_0=rep(0,604)

ETC=data.frame(Est_cl,ETC_MY,ETC_J,ETC_Jl,ETC_AG,ETC_S,ETC_0)
setwd("C:/ResultsR/Results")
write.csv(ETC, file="quantiles.csv")

#iniciojun
ETC_MY=rep(0,604)
wini=ini+15-Mond[5+1]
a=15
month_a=6
ETC_J=(ETPj*a)*kini
ETC_Jl1=ETPjL*b1*kini

b1=wini[1]
month_b1=6+1
wdes=des+b1-Mond[6+1]
ETC_Jl2=ETPjL*(Mond[6+1]-b1)*kini
ETC_Jl=ETC_Jl1+ETC_Jl2

ETC_AG1=ETPjL*b2*kini

b2=wdes[1]
month_b2=7+1
wmid=mid+b2-Mond[7+1]
ETC_AG2=ETPAG*(Mond[7+1]-b2)*kmid
ETC_AG=ETC_AG1+ETC_AG2
ETC_S1=ETPS*c*kmid
```

A.3. Códigos R

```
c=wmid[1]
month_c=8+1
wend=end+c-Mond[8+1]
ETC_S2=ETPS*(Mond[8+1]-c)*kend
ETC_S=ETC_S1+ETC_S2

e=wend[1]
month_end=9+1
ETC_0=ETPO*c*kend

ETC=data.frame(Est_c1,ETC_MY,ETC_J,ETC_J1,ETC_AG,ETC_S,ETC_0)
setwd("C:/ResultsR/Results")
write.csv(ETC, file="quantiles1.csv")
```

A.3.3. Selección de los modelos, las variables, Validación Cruzada, Estimación de probabilidades y tiempos de retorno por estación

A.3.3.1. Modelo VGAM GEV

```
#paquetes
#install.packages(c("ggplot2", "tibble", "tidyr","stringr", "forcats",
  #"readr","rlang","purrr","dplyr","tidyverse",
  #"fs","readxl","rlang","GB2", "gamlss", "VGAM"))
library(MASS)
library(ggplot2)
library(tibble)
library(tidyr)
library(stringr)
library(forcats)
library(readr)
library(rlang)
library(purrr)
library(dplyr)
library(tidyverse)
library(fs)
library(readxl)
library(rlang)
library(GB2)
library(gamlss)
library(VGAM)
#setwd("C:/ResultsR")

#Quantiles q1 = inicio en mayo y q2 = inicio en junio
q1=data.frame(read_csv("C:/ResultsR/Results/quantiles.csv"))
```

A.3. Códigos R

```
q2=data.frame(read_csv("C:/ResultsR/Results/quantiles1.csv"))

EstModelGEV=data.frame()
#Naming the Data Frame - Step 2
path <- paste("C:/Data/Est_mon.xlsm")

#For para los datos
#str(twt)
twt<-path %>% excel_sheets()
twt<-twt[-1]
#twt<-twt[-1]
z<-length(twt)
twt

#Datos de estaciones
Est= read_excel("C:/Data/Est_Etp.xlsx")
Est=filter(Est,CLAVE %in% twt)

#Est <- Est[with(twt, order(Est$CLAVE)), ] # Orden directo

Est=Est[match(twt, Est$CLAVE),]
#setwd("C:/Data")
#write.csv(Est, file="Estfilter.csv")

#Meses<-c(PP_Ene, PP_Feb, PP_Mar, PP_Abr, PP_May, PP_Jun, PP_Jul, PP_Ago,
PP_Sep, PP_Oct, PP_Nov, PP_Dic)
PP_Anual=c("PP_Ene", "PP_Feb", "PP_Mar", "PP_Abr", "PP_May", "PP_Jun", "PP_Jul",
"PP_Ago", "PP_Sep", "PP_Oct", "PP_Nov", "PP_Dic")
Month=c("Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct",
"Nov", "Dic")
nom=c(0,1,2,3,4,5,6,7,8,9,10,11)
#for para las estaciones
for (i in 1:z){
data1<- read_excel(paste("C:/Data/Est_mon.xlsm"), sheet = (i+1),
range=cell_cols(1:13))
index<-read_excel(paste("C:/index/indices.xlsx"),sheet=9)

for (w in 5:10){
eval(parse(text=paste("PP_",Month[w], "=na.omit(data.frame
(data1$Año,data1$PP_",Month[w],"))" ,sep=""))))
eval(parse(text=paste("L_",Month[w], "=length(PP_",Month[w],
"$data1.Año)" ,sep="")))) }

for (w in 5:10){
eval(parse(text=paste("PP_",Month[w], "GEV=inner_join(PP_",Month[w],
```

A.3. Códigos R

```
",index, by=c('data1.Año'='Año'))", sep=""))
eval(parse(text=paste("wc=length(PP_",Month[w],"GEV
$data1.Año)",sep="")))
set.seed(8)
rand <- sample(2, wc,replace=T, prob=c(0.7,0.3))
table(rand)/wc
# the proportions in the sample
eval(parse(text=paste("PP_",Month[w],"GEV2<-PP_",Month[w],
"GEV[rand==1,]", sep=""))) # training data
eval(parse(text=paste("PP_",Month[w],"GEV2n<-PP_",Month[w],
"GEV[rand==2,]", sep=""))) # validation data }
#VGAM GEV
for (w in 5:10){
try(eval(parse(text=paste("mod0",tw[t][i],Month[w],
"GE <- vglm(data1.PP_",Month[w],"~1, data=na.omit(PP_",Month[w],"GEV2),gevff,
trace = TRUE)",sep=""))))
try(eval(parse(text=paste("mod1",tw[t][i],Month[w],"GE <-
vglm(data1.PP_",Month[w],"~ONI_",Month[w], "+ONI_",
Month[w],":PDO_",Month[w],"+ONI_",Month[w],
":NAO_",Month[w],"+ONI_",Month[w],":NPI_",Month[w],
"+ONI_",Month[w],":ALPI_Ene,scale=~1,shape=~1,
data=na.omit(PP_",Month[w],"GEV2), gevff, trace = TRUE)",sep=""))))
try(eval(parse(text=paste("mod2",tw[t][i],Month[w],
"GE=step4vglm(mod1",tw[t][i],Month[w],"GE)", sep=""))))
if(exists(paste("mod2",tw[t][i],Month[w],"GE", sep
= ""))){
#prueba de razon de verosimilitudes
eval(parse(text=paste("df0",tw[t][i],Month[w],
"GE=mod0",tw[t][i],Month[w], "GE@df.residual",sep="")))
eval(parse(text=paste("df1",tw[t][i],Month[w],
"GE=mod1",tw[t][i],Month[w], "GE@df.residual",sep="")))
eval(parse(text=paste("df2",tw[t][i],Month[w],
"GE=mod2",tw[t][i],Month[w], "GE@df.residual",sep="")))
eval(parse(text=paste("df01",tw[t][i],Month[w],
"GE=df0",tw[t][i],Month[w], "GE-df1",tw[t][i],Month[w],
"GE",sep = "")))
eval(parse(text=paste("df02",tw[t][i],Month[w],
"GE=df0",tw[t][i],Month[w], "GE-df2",tw[t][i],Month[w],
"GE",sep = "")))
eval(parse(text=paste("l0",tw[t][i],Month[w],
"GE=logLik(mod0",tw[t][i],Month[w], "GE)", sep="")))
eval(parse(text=paste("l1",tw[t][i],Month[w],
"GE=logLik(mod1",tw[t][i],Month[w], "GE)", sep="")))
eval(parse(text=paste("l2",tw[t][i],Month[w],
"GE=logLik(mod2",tw[t][i],Month[w], "GE)", sep=""))))
```

A.3. Códigos R

```
eval(parse(text=paste("chiqs",twl[i],Month[w],
"GE=-2*(l0",twl[i],Month[w], "GE-l1",twl[i],Month[w], "GE)", sep="")))
# prueba de razon de verosim
eval(parse(text=paste("chiqs2",twl[i],Month[w],
"GE=-2*(l0",twl[i],Month[w], "GE-l2",twl[i],Month[w], "GE)", sep="")))
eval(parse(text=paste("p01",twl[i],Month[w],
"GE=pchisq(chiqs",twl[i],Month[w], "GE, df=df01",twl[i],Month[w],
"GE,lower.tail=FALSE)",sep=""))) # P value
eval(parse(text=paste("p02",twl[i],Month[w],
"GE=pchisq(chiqs2",twl[i],Month[w],
"GE, df=df02",twl[i],Month[w],
"GE, lower.tail=FALSE)", sep=""))) # P value
#AIC VGAM GEV
eval(parse(text=paste("AIC0",twl[i],Month[w],
"GE=AIC(mod0",twl[i],Month[w], "GE)", sep="")))
eval(parse(text=paste("AIC1",twl[i],Month[w],
"GE=AIC(mod1",twl[i],Month[w], "GE)", sep="")))
eval(parse(text=paste("AIC2",twl[i],Month[w],
"GE=AIC(mod2",twl[i],Month[w], "GE)", sep="")))
###Preguntar si la df es la diferencia de los gl
###residuales o tienen que ver con los parámetros
####estimados###
#AIC
#Modelo GEV
eval(parse(text=paste("pred",twl[i],Month[w],
"GEV=as.vector(predict.vlm(mod2",twl[i],Month[w],
"GE,newdata=na.omit(PP_",Month[w], "GEV2n),type=
'response')[,1]))",sep=""))) eval(parse(text=paste("PP_",Month[w], "predGE=
na.omit(PP_",Month[w], "GEV2n)$data1.PP_",Month[w],
sep="")))
#names
eval(parse(text=paste("pred",twl[i],Month[w],
"GEV=data.frame(PP_",Month[w], "predGE,pred"
,twl[i],Month[w], "GEV)", sep="")))
eval(parse(text=paste("names(pred",twl[i],Month[w],
"GEV)=c('PP','pred2GEV')",sep="")))
setwd("C:/Resultspred")
eval(parse(text=paste("write.csv(pred",twl[i],
Month[w], "GEV,file='pred",twl[i],Month[w], "GEV.
csv'",sep="")))
}else{
  if(exists(paste("mod1",twl[i],Month[w], "GE", sep = ""))){#prueba de razon de verosim
eval(parse(text=paste("df0",twl[i],Month[w],
"GE=mod0",twl[i],Month[w], "GE@df.residual",sep="")))
eval(parse(text=paste("df1",twl[i],Month[w],
```

A.3. Códigos R

```
"GE=mod1",tw[tw[i],Month[w],"GE@df.residual",sep=""))))
eval(parse(text=paste("df2",tw[tw[i],Month[w],
"GE=NA", sep=""))))
eval(parse(text=paste("df01",tw[tw[i],Month[w],
"GE=df0",tw[tw[i],Month[w],"GE-df1",tw[tw[i],Month[w],
"GE",sep = "]))))
eval(parse(text=paste("df02",tw[tw[i],Month[w],
"GE=NA",sep = "]))))
eval(parse(text=paste("l0",tw[tw[i],Month[w],
"GE=logLik(mod0",tw[tw[i],Month[w],"GE)", sep=""))))
eval(parse(text=paste("l1",tw[tw[i],Month[w],
"GE=logLik(mod1",tw[tw[i],Month[w],"GE)", sep=""))))
eval(parse(text=paste("l2",tw[tw[i],Month[w],
"GE=NA", sep=""))))
eval(parse(text=paste("chiqs",tw[tw[i],Month[w],
"GE=-2*(l0",tw[tw[i],Month[w],"GE-l1",tw[tw[i],Month[w],
"GE)", sep="")))) # prueba de razon de verosim
eval(parse(text=paste("chiqs2",tw[tw[i],Month[w],
"GE=NA", sep=""))))
eval(parse(text=paste("p01",tw[tw[i],Month[w],
"GE=pchisq(chiqs",tw[tw[i],Month[w],"GE, df=df01",tw[tw[i],Month[w],"GE,
lower.tail=FALSE)",sep="")))) # P value
eval(parse(text=paste("p02",tw[tw[i],Month[w],
"GE=NA", sep="")))) # P value
#AIC VGAM GEV
eval(parse(text=paste("AIC0",tw[tw[i],Month[w],
"GE=AIC(mod0",tw[tw[i],Month[w],"GE)", sep=""))))
eval(parse(text=paste("AIC1",tw[tw[i],Month[w],
"GE=AIC(mod1",tw[tw[i],Month[w],"GE)", sep=""))))
eval(parse(text=paste("AIC2",tw[tw[i],Month[w],
"GE=NA", sep=""))))
###Preguntar si la df es la diferencia de los gl
###residuales o tienen que ver con los parámetros
####estimados###
#AIC
#Modelo GEV
eval(parse(text=paste("pred",tw[tw[i],Month[w],
"GEV=as.vector((predict.vlm(mod1",tw[tw[i],Month[w],
"GE,newdata=na.omit(PP_",Month[w],"GEV2n),type=
'response')[,1]))",sep=""))))
eval(parse(text=paste("PP_",Month[w],"predGE=
na.omit(PP_",Month[w],"GEV2n)$data1.PP_",Month[w],
sep=""))))
#names
eval(parse(text=paste("pred",tw[tw[i],Month[w],
```

A.3. Códigos R

```
"GEV=data.frame(PP_",Month[w], "predGE,pred"
,twt[i],Month[w], "GEV", sep="")) eval(parse(text=paste("names(pred",twt[i],Month
"GEV)=c('PP','pred1GEV')",sep="")))
setwd("C:/Resultspred")
eval(parse(text=paste("write.csv(pred",twt[i],
Month[w], "GEV,file='pred",twt[i],Month[w],
"GEV.csv'",sep="")))
}else{
#prueba de razon de verosimilitudes
eval(parse(text=paste("df0",twt[i],Month[w],
"GE=mod0",twt[i],Month[w], "GE@df.residual",sep="")))
eval(parse(text=paste("df1",twt[i],Month[w],
"GE=NA", sep="")) eval(parse(text=paste("df2",twt[i],Month[w],
"GE=NA", sep="")))
eval(parse(text=paste("df01",twt[i],Month[w],
"GE=NA",sep = ")))
eval(parse(text=paste("df02",twt[i],Month[w],
"GE=NA",sep = ")))
eval(parse(text=paste("l0",twt[i],Month[w],
"GE=logLik(mod0",twt[i],Month[w], "GE)", sep="")))
eval(parse(text=paste("l1",twt[i],Month[w],
"GE=NA", sep="")))
eval(parse(text=paste("l2",twt[i],Month[w],
"GE=NA", sep="")))
eval(parse(text=paste("chiqs",twt[i],Month[w],
"GE=NA", sep="))) # prueba de razon de verosim
eval(parse(text=paste("chiqs2",twt[i],Month[w],
"GE=NA", sep=")))
eval(parse(text=paste("p01",twt[i],Month[w],
"GE=NA",sep="))) # P value
eval(parse(text=paste("p02",twt[i],Month[w],
"GE=NA", sep="))) # P value
#AIC VGAM GEV
eval(parse(text=paste("AIC0",twt[i],Month[w],
"GE=AIC(mod0",twt[i],Month[w], "GE)", sep=")))
eval(parse(text=paste("AIC1",twt[i],Month[w],
"GE=NA", sep=")))
eval(parse(text=paste("AIC2",twt[i],Month[w],
"GE=NA", sep=")))
###Preguntar si la df es la diferencia de los gl
###residuales o tienen que ver con los parámetros
####estimados###
#AIC
#Modelo GEV
eval(parse(text=paste("pred",twt[i],Month[w],
```

A.3. Códigos R

```
"GEV=as.vector((predict.vlm(mod0",twl[i],Month[w],
"GE,newdata=na.omit(PP_",Month[w],"GEV2n),type=
'response')[,1]))",sep=""))
```

```
eval(parse(text=paste("PP_",Month[w],"predGE=na.
omit(PP_",Month[w],"GEV2n)$data1.PP_",Month[w], sep=""))
#names
eval(parse(text=paste("pred",twl[i],Month[w],"GEV
=data.frame(PP_",Month[w],"predGE,pred",twl[i],
Month[w],"GEV)", sep="")))
eval(parse(text=paste("names(pred",twl[i],Month[w],
"GEV)=c('PP','pred0GEV')",sep="")))
setwd("C:/Resultspred")
eval(parse(text=paste("write.csv(pred",twl[i],
Month[w],"GEV,file='pred",twl[i],Month[w],"GEV.csv')",sep="")))
} } }
eval(parse(text=paste("AIC0",twl[i],"GEV=c(AIC0",
twl[i],"MayGE,AIC0",twl[i],"JunGE,AIC0",twl[i],
"JulGE,AIC0",twl[i],"AgoGE,AIC0",twl[i],"SepGE,
AIC0",twl[i],"OctGE)", sep=""))))
```

```
eval(parse(text=paste("AIC1",twl[i],"GEV=c(AIC1",
twl[i],"MayGE,AIC1",twl[i],"JunGE,AIC1",twl[i],
"JulGE,AIC1",twl[i],"AgoGE,AIC1",twl[i],"SepGE,
AIC1",twl[i],"OctGE)", sep=""))))
```

```
eval(parse(text=paste("AIC2",twl[i],"GEV=c(AIC2",
twl[i],"MayGE,AIC2",twl[i],"JunGE,AIC2",twl[i],
"JulGE,AIC2",twl[i],"AgoGE,AIC2",twl[i],"SepGE,AIC2",
twl[i],"OctGE)", sep=""))))
```

```
eval(parse(text=paste("df0",twl[i],"GEV=c(df0",twl[i]
,"MayGE,df0",twl[i],"JunGE,df0",twl[i],"JulGE,df0",
twl[i],"AgoGE,df0",twl[i],"SepGE,df0",twl[i],"OctGE)
", sep=""))))
```

```
eval(parse(text=paste("df1",twl[i],"GEV=c(df1",twl[i]
,"MayGE,df1",twl[i],"JunGE,df1",twl[i],"JulGE,df1",
", sep=""))))
```

twl[i], "Ago

```
eval(parse(text=paste("df2",twl[i],"GEV=c(df2",twl[i]
,"MayGE,df2",twl[i],"JunGE,df2",twl[i],"JulGE,df2",
twl[i],"AgoGE,df2",twl[i],"SepGE,df2",twl[i],"OctGE)
", sep=""))))
```


A.3. Códigos R

```
eval(parse(text=paste("l1",tw[t[i]],"GEV=c(l1",tw[t[i]],
"MayGE,l1",tw[t[i]],"JunGE,l1",tw[t[i]],"JulGE,l1",
tw[t[i]],"AgoGE,l1",tw[t[i]],"SepGE,l1",tw[t[i]],"OctGE)
", sep="")))

eval(parse(text=paste("l2",tw[t[i]],"GEV=c(l2",tw[t[i]],
"MayGE,l2",tw[t[i]],"JunGE,l2",tw[t[i]],"JulGE,l2",
tw[t[i]],"AgoGE,l2",tw[t[i]],"SepGE,l2",tw[t[i]],"OctGE)
", sep="")))

eval(parse(text=paste("l0",tw[t[i]],"GEV=c(l0",tw[t[i]],
"MayGE,l0",tw[t[i]],"JunGE,l0",tw[t[i]],"JulGE,l0",
tw[t[i]],"AgoGE,l0",tw[t[i]],"SepGE,l0",tw[t[i]],"OctGE)
", sep="")))

eval(parse(text=paste("chigs01",tw[t[i]],"GEV=c(chigs"
,tw[t[i]],"MayGE,chigs",tw[t[i]],"JunGE,chigs",tw[t[i]],
"JulGE,chigs",tw[t[i]],"AgoGE,chigs",tw[t[i]],"SepGE,
chigs",tw[t[i]],"OctGE)", sep="")))

eval(parse(text=paste("chigs02",tw[t[i]],"GEV=c(chigs2"
,tw[t[i]],"MayGE,chigs2",tw[t[i]],"JunGE,chigs2",tw[t[i]],
"JulGE,chigs2",tw[t[i]],"AgoGE,chigs2",tw[t[i]],"SepGE,
chigs2",tw[t[i]],"OctGE)", sep="")))

eval(parse(text=paste("p01",tw[t[i]],"GEV=c(p01",tw[t[i]]
,"MayGE,p01",tw[t[i]],"JunGE,p01",tw[t[i]],"JulGE,p01"
,tw[t[i]],"AgoGE,p01",tw[t[i]],"SepGE,p01",tw[t[i]],
"OctGE)", sep=""))) #P-value

eval(parse(text=paste("p02",tw[t[i]],"GEV=c(p02",tw[t[i]]
,"MayGE,p02",tw[t[i]],"JunGE,p02",tw[t[i]],"JulGE,p02",
tw[t[i]],"AgoGE,p02",tw[t[i]],"SepGE,p02",tw[t[i]],
"OctGE)", sep="")))#P-value

eval(parse(text=paste("est",tw[t[i]],"GEV=data.frame(
Est[i,3],Month[5:10],AICO",tw[t[i]],"GEV, AIC1"
,tw[t[i]],"GEV,AIC2",tw[t[i]],"GEV, df0",tw[t[i]],"GEV,
df2",tw[t[i]],"GEV, l0",tw[t[i]],"GEV, l1",tw[t[i]],
"GEV,l2",tw[t[i]],"GEV,chigs01",tw[t[i]],"GEV, chigs02",
tw[t[i]],"GEV, p01",tw[t[i]],"GEV,p02",tw[t[i]],
"GEV)", sep="")))

eval(parse(text=paste("names(est",tw[t[i]],"GEV) <-
c('Est','Mes','AICOGEV', 'AIC1GEV', 'AIC2GEV',
```

A.3. Códigos R

```
'df01GEV', 'df02GEV', 'l0GEV', 'l1GEV', 'l2GEV',
'chisq01GEV', 'chisq02GEV', 'p01GEV', 'p02GEV')", sep=""))))

#Using rbind() function to insert above observation
eval(parse(text=paste("EstModelGEV= rbind(EstModelGEV,
est",twt[i],"GEV)", sep="")))

write.csv(EstModelGEV, file="EstModelGEV.csv")

rt=data.frame()
Coef=data.frame()
for(i in 1:z){
  for(w in 5:10){
    if(exists(paste("mod2",twt[i],Month[w],"GE"
,sep=""))){
eval(parse(text=paste("r",twt[i],Month[w],"=length
(Coef(mod2",twt[i],Month[w],"GE))", sep="")))
eval(parse(text=paste("Coef",twt[i],Month[w],
"GEV=Coef(mod2",twt[i],Month[w],"GE)",sep="")))
}else{
if(exists(paste("mod1",twt[i],Month[w],"GE"))){
eval(parse(text=paste("r",twt[i],Month[w],
"=length(Coef(mod1",twt[i],Month[w],"GE))",sep="")))
eval(parse(text=paste("Coef",twt[i],Month[w],
"GEV=Coef(",twt[i],"mod1",twt[i],Month[w],"GE)",sep="")))
}else{
eval(parse(text=paste("r",twt[i],Month[w],"=
length(Coef(mod0",twt[i],Month[w],"GE))",sep="")))
eval(parse(text=paste("Coef",twt[i],Month[w],
"GEV=Coef(mod0",twt[i],Month[w],"GE)",sep=""))) }}
eval(parse(text=paste("Coef",twt[i],Month[w],
"GEV1=c(",twt[i],"",w,"Coef",twt[i],Month[w],
"GEV)", sep="")))
eval(parse(text=paste("r",twt[i],Month[w],
"=data.frame(",twt[i],"",w,"r",twt[i],Month[w],
)",sep="")))
eval(parse(text=paste("Coef=rbind(Coef,Coef",
twt[i],Month[w],"GEV1)",sep="")))
eval(parse(text=paste("names(Coef)=c('Est',
'Mes','location','scale','shape')",sep="")))
eval(parse(text=paste("names(r",twt[i],Month[w],
")=c('Est','Mes','length')",sep="")))
eval(parse(text=paste("rt= rbind(rt,r",
twt[i],Month[w],")", sep=""))) }}
k=1
```

A.3. Códigos R

```
p1=data.frame()
p2=data.frame()
T1=data.frame()
T2=data.frame()
for(i in 1:z){
  #i=1
  Coef[k,1]
  Coef[k,2]

  eval(parse(text=paste("p1",twt[i],"May=1-pgev
(",q1[i,3],"",Coef[k,3],Coef[k,4],Coef[k,5])" , sep="")))

  eval(parse(text=paste("p1",twt[i],"Jun=1-pgev
(",q1[i,4],"",Coef[k+1,3],Coef[k,4],Coef[k,5])" , sep="")))

  eval(parse(text=paste("p1",twt[i],"Jul=1-pgev
(",q1[i,5],"",Coef[k+2,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p1",twt[i],"Ago=1-pgev
(",q1[i,6],"",Coef[k+3,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p1",twt[i],"Sep=1-pgev
(",q1[i,7],"",Coef[k+4,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p1",twt[i],"Oct=1-pgev
(",q1[i,8],"",Coef[k+5,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p1",twt[i],"=c(",twt[i],"
,p1",twt[i],"May,p1",twt[i],"Jun,p1",twt[i],"Jul,
p1",twt[i],"Ago,p1",twt[i],"Sep,p1",twt[i],
"Oct)",sep="")))
  eval(parse(text=paste("p1=rbind(p1,p1",twt[i],"")
,sep="")))
  eval(parse(text=paste("names(p1",twt[i],"")=c('Est',
'p1May','p1Jun','p1Jul','p1Ago','p1Sep','p1Oct')"
,sep="")))
  eval(parse(text=paste("names(p1)=c('Est','p1May',
'p1Jun','p1Jul','p1Ago','p1Sep','p1Oct')",sep=")))
  eval(parse(text=paste("p2",twt[i],"May=1-pgev
(",q2[i,3],"",Coef[k,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p2",twt[i],"Jun=1-pgev
(",q2[i,4],"",Coef[k+1,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p2",twt[i],"Jul=1-pgev
(",q2[i,5],"",Coef[k+2,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p2",twt[i],"Ago=1-pgev
(",q2[i,6],"",Coef[k+3,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p2",twt[i],"Sep=1-pgev
(",q2[i,7],"",Coef[k+4,3],Coef[k,4],Coef[k,5])" , sep="")))
  eval(parse(text=paste("p2",twt[i],"Oct=1-pgev
```

A.3. Códigos R

```
(" ,q2[i,8] , " ,Coef[k+5,3] ,Coef[k,4] ,Coef[k,5])" , sep=""))
eval(parse(text=paste("p2" ,tw[tw[i] , "=c(" ,tw[tw[i] ,
" ,p2" ,tw[tw[i] , "May,p2" ,tw[tw[i] , "Jun,p2" ,tw[tw[i] ,
"Jul,p2" ,tw[tw[i] , "Ago,p2" ,tw[tw[i] , "Sep,p2" ,tw[tw[i] ,
"Oct)" , sep=""))))
eval(parse(text=paste("p2=rbind(p2,p2" ,tw[tw[i] , ")"
, sep=""))))
eval(parse(text=paste("names(p2" ,tw[tw[i] , ")=c('Est' ,
'p2May' , 'p2Jun' , 'p2Jul' , 'p2Ago' , 'p2Sep' , 'p2Oct')" ,
sep=""))))
eval(parse(text=paste("names(p2)=c('Est' , 'p2May' ,
'p2Jun' , 'p2Jul' , 'p2Ago' , 'p2Sep' , 'p2Oct')" , sep=""))))
k=k+6
eval(parse(text=paste("T1" ,tw[tw[i] , "May=1/p1" ,
tw[tw[i] , "May" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "Jun=1/p1" ,
tw[tw[i] , "Jun" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "Jul=1/p1" ,
tw[tw[i] , "Jul" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "Ago=1/p1" ,
tw[tw[i] , "Ago" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "Sep=1/p1" ,
tw[tw[i] , "Sep" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "Oct=1/p1" ,
tw[tw[i] , "Oct" , sep=""))))
eval(parse(text=paste("T1" ,tw[tw[i] , "=c(" ,tw[tw[i] , "
, T1" ,tw[tw[i] , "May,T1" ,tw[tw[i] , "Jun,T1" ,tw[tw[i] , "Jul,
T1" ,tw[tw[i] , "Ago,T1" ,tw[tw[i] , "Sep,T1" ,tw[tw[i] , "Oct)"
, sep=""))))
eval(parse(text=paste("T1=rbind(T1,T1" ,tw[tw[i] , ")"
, sep=""))))
eval(parse(text=paste("names(T1" ,tw[tw[i] , ")=c('Est' ,
'T1May' , 'T1Jun' , 'T1Jul' , 'T1Ago' , 'T1Sep' , 'T1Oct')" ,
sep=""))))
eval(parse(text=paste("names(T1)=c('Est' , 'T1May' ,
'T1Jun' , 'T1Jul' , 'T1Ago' , 'T1Sep' , 'T1Oct')" , sep=""))))
eval(parse(text=paste("T2" ,tw[tw[i] , "May=1/p2" ,
tw[tw[i] , "May" , sep=""))))
eval(parse(text=paste("T2" ,tw[tw[i] , "Jun=1/p2" ,
tw[tw[i] , "Jun" , sep=""))))
eval(parse(text=paste("T2" ,tw[tw[i] , "Jul=1/p2" ,
tw[tw[i] , "Jul" , sep=""))))
eval(parse(text=paste("T2" ,tw[tw[i] , "Ago=1/p2" ,
tw[tw[i] , "Ago" , sep=""))))
eval(parse(text=paste("T2" ,tw[tw[i] , "Sep=1/p2" ,
```

A.3. Códigos R

```
  twt[i], "Sep", sep=""))
  eval(parse(text=paste("T2", twt[i], "Oct=1/p2",
  twt[i], "Oct", sep="")))
  eval(parse(text=paste("T2", twt[i], "=c(", twt[i], ",
  T2", twt[i], "May,T2", twt[i], "Jun,T2", twt[i], "Jul,T2"
  , twt[i], "Ago,T2", twt[i], "Sep,T2", twt[i], "Oct)",
  sep="")))
  eval(parse(text=paste("T2=rbind(T2,T2", twt[i], ")\"", sep="")))
  eval(parse(text=paste("names(T2", twt[i], ")=c('Est',
  'T2May', 'T2Jun', 'T2Jul', 'T2Ago', 'T2Sep', 'T2Oct')\"", sep="")))
  eval(parse(text=paste("names(T2)=c('Est', 'T2May',
  'T2Jun', 'T2Jul', 'T2Ago', 'T2Sep', 'T2Oct')\"", sep="")))})

Est1=c(Est[3], Est[8], Est[9])
Est1=data.frame(Est1)
Est1$CLAVE[19]=5025
Est1$LATD[19]=25.50
Est1$LOND[19]=-102.5
Est1[1,19]
names(Est1)=c('Est', 'LatD', 'LonD')
head(pTGEV)
head(Est1)
ppGEV=inner_join(p1,p2,by=c("Est","Est"))
TTGEV=inner_join(T1,T2,by=c("Est","Est"))
pTGEV=inner_join(ppGEV,TTGEV,by=c("Est","Est"))
EpTGEV=inner_join(Est1,pTGEV,by=c("Est","Est"))

write.csv(EpTGEV, file="EstppTTGEV.csv")

A.3.3.2. Modelos GAMLSS Beta Generalizada tipo II (GB2), Gamma
          Generalizada (GG) y Gamma (GA)

#paquetes
#install.packages(c("ggplot2", "tibble", "tidyr","stringr", "forcats",
#                   "readr", "rlang", "purrr", "dplyr", "tidyverse", "fs",
#                   "readxl", "rlang", "GB2", "gamlss", "VGAM"))
library(MASS)
library(ggplot2)
library(tibble)
library(tidyr)
library(stringr)
library(forcats)
library(readr)
library(rlang)
library(purrr)
```

A.3. Códigos R

```
library(dplyr)
library(tidyverse)
library(fs)
library(readxl)
library(rlang)
library(GB2)
library(gamlss)
library(VGAM)
#setwd("C:/ResultsR")

#Quantiles q1 = inicio en mayo y q2 = inicio en junio
q1=data.frame(read_csv("C:/ResultsR/Results/quantiles.csv"))
q2=data.frame(read_csv("C:/ResultsR/Results/quantiles1.csv"))

EstModelGAMLSS=data.frame()
#Naming the Data Frame - Step 2

path <- paste("C:/Data/Est_mon.xlsm")

#For para los datos
#str(twt)
twt<-path %>% excel_sheets()
twt<-twt[-1]
#twt<-twt[-1]
z<-length(twt)
twt

#Datos de estaciones
Est= read_excel("C:/Data/Est_Etp.xlsx")
Est=filter(Est,CLAVE %in% twt)

#Est <- Est[with(twt, order(Est$CLAVE)), ] # Orden directo

Est=Est[match(twt, Est$CLAVE),]
#setwd("C:/Data")
#write.csv(Est, file="Estfilter.csv")

PP_Anual=c("PP_Ene", "PP_Feb", "PP_Mar", "PP_Abr", "PP_May", "PP_Jun",
"PP_Jul", "PP_Ago", "PP_Sep", "PP_Oct", "PP_Nov", "PP_Dic")
Month=c("Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct",
"Nov", "Dic")
nom=c(0,1,2,3,4,5,6,7,8,9,10,11)

for(i in 1:z){
```

A.3. Códigos R

```
data1<- read_excel(paste("C:/Data/Est_mon.xlsm"), sheet = (i+1),
range=cell_cols(1:13))
index<-read_excel(paste("C:/index/indices.xlsx"),sheet=9)
#head(data1)

#data1=na.omit(data1)
for (w in 5:10){
eval(parse(text=paste("PP_",Month[w],
"=na.omit(data.frame(data1$Año,data1$PP_",Month[w],"))" ,sep=""))))
eval(parse(text=paste("L_",Month[w] ,"=length(PP_",
Month[w] ,"$data1.Año)" ,sep="")))) }
for (w in 5:10){
eval(parse(text=paste("zero_",Month[w] ,
"=filter(data1,PP_",Month[w] ,"==0)" , sep=""))))
eval(parse(text=paste("zero_",Month[w] ,"1=data.frame(zero_",
Month[w] ,"$Año,zero_",Month[w] ,"$PP_",Month[w] ,")" , sep=""))))
eval(parse(text=paste("lzero",Month[w] ,"=length(zero_",Month[w] ,
"1$zero_",Month[w] ,".Año)" , sep=""))))
eval(parse(text=paste("(per0",Month[w] ,"=lzero",Month[w] ,
"/L_",Month[w] ,")" , sep=""))))}

for (w in 5:10){
eval(parse(text=paste("PP_",Month[w] ,"=data.frame(PP_",
Month[w] ,")" ,sep=""))))
eval(parse(text=paste("PP_",Month[w] ,"1=filter(PP_",
Month[w] ," ,PP_",Month[w] ,"$data1.PP_",Month[w] ,">0)" ,sep=""))))
}

index=data.frame(index)
wa=length(data$Año)
for (w in 5:10){
eval(parse(text=paste("PP_",Month[w] ,"1=inner_join(PP_",
Month[w] ,"1,index,by=c('data1.Año'='Año'))" ,sep=""))))
eval(parse(text=paste("wa=length(PP_",Month[w] ,
"1$data1.Año)" ,sep=""))))
set.seed(8)
rand <- sample(2, wa,replace=T, prob=c(0.7,0.3))
table(rand)/wa
# the proportions in the sample

eval(parse(text=paste("PP_",Month[w] ,"2<-PP_",Month[w] ,
"1[rand==1,]" , sep="")))) # training data
eval(parse(text=paste("PP_",Month[w] ,"2n<-PP_",Month[w] ,
"1[rand==2,]" , sep="")))) # validation data
#names(PP_May2)
```

A.3. Códigos R

```
eval(parse(text=paste("wb",Month[w],"=length(PP_",
Month[w],"2$data1.Año)",sep="")))
eval(parse(text=paste("Alt",Month[w],
"=rep(as.numeric(Est[i,7]),wb",Month[w],")",
sep="")))
eval(parse(text=paste("Lat",Month[w],
"=rep(as.numeric(Est[i,8]),wb",Month[w],")",
sep="")))
eval(parse(text=paste("Long1",Month[w],
"=rep(as.numeric(Est[i,9]),wb",Month[w],")",
sep="")))
eval(parse(text=paste("Long",Month[w],
"=rep(as.numeric(Est[i,10]),wb",Month[w],")",
sep="")))
#names(PP_May2)

eval(parse(text=paste("Año_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[1])", sep = ""))),
")", sep="")))
eval(parse(text=paste("PP_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[2])", sep = ""))),
")", sep="")))
eval(parse(text=paste("ALPI",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[3])", sep = ""))),
")", sep="")))
eval(parse(text=paste("AMOs_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[3+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("AMOs_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[15+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("NAO_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[27+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("NPI_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[39+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("ONI_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[51+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("PDO_",Month[w],"<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[63+w])", sep = ""))),
")", sep="")))
eval(parse(text=paste("Año_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],",2)[1])", sep = ""))),
```


A.3. Códigos R

```
)", sep=""))
eval(parse(text=paste("PP_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[2])", sep = ""))),
)", sep=""))
eval(parse(text=paste("ALPI_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[3])", sep = ""))),
)", sep=""))
eval(parse(text=paste("AMOs_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[3+w])", sep = ""))),
)", sep=""))
eval(parse(text=paste("AMOUS_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[15+w])", sep = ""))),
)", sep=""))
eval(parse(text=paste("NAO_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[27+w])", sep = ""))),
)", sep=""))
eval(parse(text=paste("NPI_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[39+w])", sep = ""))),
)", sep=""))
eval(parse(text=paste("ONI_",Month[w],"n<- c(PP_",Month[w],
"2$",eval(parse(text=paste("(names(PP_",Month[w],"2)[51+w])", sep = ""))),
)", sep=""))
eval(parse(text=paste("PDO_",Month[w],"n<- c(PP_",Month[w],
"2n$",eval(parse(text=paste("(names(PP_",Month[w],"2)[63+w])",
sep = ""))),)", sep=""))
}

for(w in 5:10){
eval(parse(text=paste("PP_",Month[w],"dat=data.frame(PP_",Month[w],"",ONI_",
Month[w],"",PDO_",Month[w],"",NAO_",Month[w],"",AMOs_",Month[w],"",NPI_",Month[w],
",ALPI",Month[w],"",Lat",Month[w],"",Long",Month[w],"",Alt",Month[w],"", sep=""))))
}

#GAMLSS GEB
for(w in 5:10){
eval(parse(text=paste("mod0",twi[i],Month[w],"GEB=gamlss(PP_",Month[w],"~1,
data=na.omit(PP_",Month[w],"dat),family=GB2(),method=mixed(1,1000)",sep=""))))

eval(parse(text=paste("mod1",twi[i],Month[w],"GEB=gamlss(PP_",Month[w],"~Lat",
Month[w],"~Long",Month[w],"~Alt",Month[w],"~ONI_",Month[w],"~ONI_",Month[w],
":PDO_",Month[w],"~ONI_",Month[w],"~AMOs_",Month[w],"~ONI_",Month[w],"~NAO_",
Month[w],"~ONI_",Month[w],"~NPI_",Month[w],"~ONI_",Month[w],"~ALPI",Month[w],
",data=na.omit(PP_",Month[w],"dat), family=GB2(), method=mixed(1,1000))",
sep=""))))
eval(parse(text=paste("mod2",twi[i],Month[w],"GEB<-stepGAIC(mod1",
```

A.3. Códigos R

```
twt[i],Month[w],"GEB,direction='both')", sep=""))
eval(parse(text=paste("mod2",twt[i],Month[w],"GEB$anova",sep="")))
eval(parse(text=paste("mod4",twt[i],Month[w],"GEB<-stepGAIC(mod2",twt[i],
Month[w],"GEB,what='sigma',direction='both',scope=~Lat",Month[w],
"+Long",Month[w],"+Alt",Month[w],"+ONI_",Month[w],"+ONI_",Month[w],
":PDO_",Month[w],"+ONI_",Month[w],":AMOs_",Month[w],"+ONI_",Month[w],
":NAO_",Month[w],"+ONI_",Month[w],":NPI_",Month[w],"+ONI_",Month[w],
":ALPI",Month[w],")",sep="")))

eval(parse(text=paste("mod4",twt[i],Month[w],"GEB$anova",sep="")))

eval(parse(text=paste("mod5",twt[i],Month[w],"GEB<-stepGAIC(mod4",
twt[i],Month[w],"GEB,what='nu',direction='both',scope=~Lat",Month[w],
"+Long",Month[w],"+Alt",Month[w],"+ONI_",Month[w],"+ONI_",Month[w],
":PDO_",Month[w],"+ONI_",Month[w],":AMOs_",Month[w],"+ONI_",Month[w],
":NAO_",Month[w],"+ONI_",Month[w],":NPI_",Month[w],"+ONI_",Month[w],
":ALPI",Month[w],")",sep="")))
eval(parse(text=paste("mod5",twt[i],Month[w],"GEB$anova",sep="")))

eval(parse(text=paste("mod5",twt[i],Month[w],"GEB$anova",sep="")))
eval(parse(text=paste("mod6",twt[i],Month[w],"GEB<-stepGAIC(mod5",
twt[i],Month[w],"GEB,what='tau',direction='both',scope=~Lat",Month[w],
"+Long",Month[w],"+Alt",Month[w],"+ONI_",Month[w],"+ONI_",Month[w],
":PDO_",Month[w],"+ONI_",Month[w],":AMOs_",Month[w],"+ONI_",Month[w],
":NAO_",Month[w],"+ONI_",Month[w],":NPI_",Month[w],"+ONI_",Month[w],
":ALPI",Month[w],")",sep="")))

eval(parse(text=paste("mod6",twt[i],Month[w],"GEB$anova",sep="")))

eval(parse(text=paste("AIC0",twt[i],Month[w],"GEB=GAIC(mod0",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("AIC1",twt[i],Month[w],"GEB=GAIC(mod1",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("AIC2",twt[i],Month[w],"GEB=GAIC(mod6",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("l0",twt[i],Month[w],"GEB=logLik(mod0",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("l1",twt[i],Month[w],"GEB=logLik(mod1",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("l2",twt[i],Month[w],"GEB=logLik(mod6",twt[i],
Month[w],"GEB)", sep="")))
eval(parse(text=paste("chigs01",twt[i],Month[w],"GEB=as.numeric(-2*(l0",
twt[i],Month[w],"GEB-l1",twt[i],Month[w],"GEB))", sep="")))
# prueba de razon de verosim
eval(parse(text=paste("chigs02",twt[i],Month[w],"GEB=as.numeric(-2*(l0",
```

A.3. Códigos R

```

tw[twt[i],Month[w],"GEB-l2",tw[twt[i],Month[w],"GEB"))", sep="")]
# prueba de razon de verosim
eval(parse(text=paste("df01",tw[twt[i],Month[w],
"GEB=mod0",tw[twt[i],Month[w],"GEB$df.residual-mod1",tw[twt[i],
Month[w],"GEB$df.residual", sep=""])))
eval(parse(text=paste("df02",tw[twt[i],Month[w],
"GEB=mod0",tw[twt[i],
Month[w],"GEB$df.residual-mod6",tw[twt[i],Month[w],
"GEB$df.residual", sep=""])))
eval(parse(text=paste("p01",tw[twt[i],Month[w],
"GEB=pchisq(chiqs01",tw[twt[i],Month[w],"GEB, df=df01",tw[twt[i],
Month[w],"GEB, lower.tail=FALSE)", sep=""]))) # P value
eval(parse(text=paste("p02",tw[twt[i],Month[w],
"GEB=pchisq(chiqs02",tw[twt[i],Month[w],"GEB, df=df02",tw[twt[i],
Month[w],"GEB, lower.tail=FALSE)", sep=""]))) # P value
}

for (w in 5:10) {
  #GAMLSS GAMMA
eval(parse(text=paste("mod0",tw[twt[i],Month[w],
"GA=gamlss(PP_",Month[w],"~1, data=na.omit(PP_",
Month[w],"dat), family=GA, method=mixed(1,1000))",
sep=""])))

eval(parse(text=paste("mod1",tw[twt[i],Month[w],"GA =gamlss(PP_",
Month[w],"~Lat",Month[w],"~Long",Month[w],"~Alt",Month[w],
"+ONI_",Month[w],"~ONI_",Month[w],"~PDO_",Month[w],"~ONI_",
Month[w],"~AMOs_",Month[w],"~ONI_",Month[w],"~NAO_",Month[w],
"+ONI_",Month[w],"~NPI_",Month[w],"~ONI_",Month[w],"~ALPI",
Month[w],"~",data=na.omit(PP_",Month[w],"dat), family=GA,
method=mixed(1,1000))",sep=""])))

eval(parse(text=paste("mod2",tw[twt[i],Month[w],"GA<- stepGAIC(mod1",
tw[twt[i],Month[w],"GA,direction='both')",sep=""])))

eval(parse(text=paste("mod2",tw[twt[i],Month[w],"GA$anova",sep=""])))

eval(parse(text=paste("mod4",tw[twt[i],Month[w],"GA<-stepGAIC(mod2",
tw[twt[i],Month[w],"GA,what='sigma',direction='both',
scope=~Lat",Month[w],"~Long",Month[w],"~Alt",Month[w],
"+ONI_",Month[w],"~ONI_",Month[w],"~PDO_",Month[w],
"+ONI_",Month[w],"~AMOs_",Month[w],"~ONI_",Month[w],
":NAO_",Month[w],"~ONI_",Month[w],"~NPI_",Month[w],
"+ONI_",Month[w],"~ALPI",Month[w],")",sep=""])))

```

A.3. Códigos R

```
eval(parse(text=paste("mod4",twl[i],Month[w],"GA$anova",sep="")))
```

```
eval(parse(text=paste("AIC0",twl[i],Month[w],"GA=GAIC(mod0",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("AIC1",twl[i],Month[w],"GA=GAIC(mod1",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("AIC2",twl[i],Month[w],"GA=GAIC(mod4",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("l0",twl[i],Month[w],"GA=logLik(mod0",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("l1",twl[i],Month[w],"GA=logLik(mod1",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("l2",twl[i],Month[w],"GA=logLik(mod4",  
twl[i],Month[w],"GA)", sep="")))
```

```
eval(parse(text=paste("chiqs01",twl[i],Month[w],  
"GA=as.numeric(-2*(l0",twl[i],Month[w],"GA-l1",twl[i],  
Month[w],"GA))", sep=""))) # prueba de razon de verosim
```

```
eval(parse(text=paste("chiqs02",twl[i],Month[w],  
"GA=as.numeric(-2*(l0",twl[i],Month[w],"GA-l2",twl[i],  
Month[w],"GA))", sep=""))) # prueba de razon de verosim
```

```
eval(parse(text=paste("df01",twl[i],Month[w],  
"GA=mod0",twl[i],Month[w],"GA$df.residual-mod1",twl[i],  
Month[w],"GA$df.residual", sep="")))
```

```
eval(parse(text=paste("df02",twl[i],Month[w],  
"GA=mod0",twl[i],Month[w],"GA$df.residual-mod4",twl[i],  
Month[w],"GA$df.residual", sep="")))
```

```
eval(parse(text=paste("p01",twl[i],Month[w],  
"GA=pchisq(chiqs01",twl[i],Month[w],"GA, df=df01",twl[i],  
Month[w],"GA, lower.tail=FALSE)", sep=""))) # P value
```

```
eval(parse(text=paste("p02",twl[i],Month[w],  
"GA=pchisq(chiqs02",twl[i],Month[w],"GA, df=df02",twl[i],  
Month[w],"GA, lower.tail=FALSE)", sep=""))) # P value
```

```
}
```

```
#GAMLSS GAMMA Generalizada
```

```
for(w in 5:10){
```

```
eval(parse(text=paste("mod0",twl[i],Month[w],  
"GG=gamlss(PP_",Month[w],"~1, data=na.omit(PP_",  
Month[w],"dat),family=GG,method=mixed(1,1000))",sep="")))
```

```
eval(parse(text=paste("mod1",twl[i],Month[w],"GG =gamlss(PP_",  
Month[w],"~Lat",Month[w]," +Long",Month[w]," +Alt",Month[w],  
"+ONI_",Month[w]," +ONI_",Month[w]," :PDO_",Month[w]," +ONI_",  
Month[w]," :NAO_",Month[w]," +ONI_",Month[w]," :NPI_",Month[w],  
"+ONI_",Month[w]," :ALPI",Month[w]," ,data=na.omit(PP_",
```

A.3. Códigos R

```
Month[w], "dat", family=GG, method=mixed(1,1000))", sep=""))

eval(parse(text=paste("mod2", twt[i], Month[w], "GG<- stepGAIC(mod1",
twt[i], Month[w], "GG,direction='both')", sep="")))
eval(parse(text=paste("mod2", twt[i], Month[w], "GG$anova", sep="")))

eval(parse(text=paste("mod4", twt[i], Month[w], "GG<-stepGAIC(mod2",
twt[i], Month[w], "GG,what='sigma', direction='both', scope=~Lat",
Month[w], "+Long", Month[w], "+Alt", Month[w], "+ONI_", Month[w],
"+ONI_", Month[w], ":PDO_", Month[w], "+ONI_", Month[w], ":NAO_",
Month[w], "+ONI_", Month[w], ":NPI_", Month[w], "+ONI_", Month[w],
":ALPI", Month[w], ")"), sep="")))

eval(parse(text=paste("mod4", twt[i], Month[w], "GG$anova", sep="")))

eval(parse(text=paste("mod5", twt[i], Month[w], "GG<-stepGAIC(mod4",
twt[i], Month[w], "GG,what='nu', direction='both', scope=~Lat",
Month[w], "+Long", Month[w], "+Alt", Month[w], "+ONI_", Month[w],
"+ONI_", Month[w], ":PDO_", Month[w], "+ONI_", Month[w], ":NAO_",
Month[w], "+ONI_", Month[w], ":NPI_", Month[w], "+ONI_", Month[w],
":ALPI", Month[w], ")"), sep="")))

eval(parse(text=paste("mod5", twt[i], Month[w], "GG$anova", sep="")))

eval(parse(text=paste("AIC0", twt[i], Month[w], "GG=GAIC(mod0",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("AIC1", twt[i], Month[w], "GG=GAIC(mod1",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("AIC2", twt[i], Month[w], "GG=GAIC(mod4",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("l0", twt[i], Month[w], "GG=logLik(mod0",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("l1", twt[i], Month[w], "GG=logLik(mod1",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("l2", twt[i], Month[w], "GG=logLik(mod4",
twt[i], Month[w], "GG)", sep="")))
eval(parse(text=paste("chqs01", twt[i], Month[w],
"GG=as.numeric(-2*(l0", twt[i], Month[w], "GG-l1", twt[i],
Month[w], "GG))", sep=""))) # prueba de razon de verosim
eval(parse(text=paste("chqs02", twt[i], Month[w],
"GG=as.numeric(-2*(l0", twt[i], Month[w], "GG-l2", twt[i],
Month[w], "GG))", sep=""))) # prueba de razon de verosim
eval(parse(text=paste("df01", twt[i], Month[w],
"GG=mod0", twt[i], Month[w], "GG$df.residual-mod1", twt[i],
Month[w], "GG$df.residual", sep=""))))
```

A.3. Códigos R

```
eval(parse(text=paste("df02",twi[i],Month[w],
"GG=mod0",twi[i],Month[w],"GG$df.residual-mod4",twi[i],
Month[w],"GG$df.residual", sep="")))
eval(parse(text=paste("p01",twi[i],Month[w],
"GG=pchisq(chiqs01",twi[i],Month[w],"GG, df=df01",twi[i],
Month[w],"GG, lower.tail=FALSE)", sep=""))) # P value
eval(parse(text=paste("p02",twi[i],Month[w],
"GG=pchisq(chiqs02",twi[i],Month[w],"GG, df=df02",twi[i],
Month[w],"GG, lower.tail=FALSE)", sep=""))) # P value
#datos predichos
for(w in 5:10){
eval(parse(text=paste("PP_",Month[w],"=PP_",Month[w],
"n",sep="")))
eval(parse(text=paste("ONI_",Month[w],"=ONI_",Month[w],
"n",sep="")))
eval(parse(text=paste("PDO_",Month[w],"=PDO_",Month[w],
"n",sep="")))
eval(parse(text=paste("NAO_",Month[w],"=NAO_",Month[w],
"n",sep="")))
eval(parse(text=paste("AMOs_",Month[w],"=AMOs_",Month[w],
"n",sep="")))
eval(parse(text=paste("NPI_",Month[w],"=NPI_",Month[w],
"n",sep="")))
eval(parse(text=paste("ALPI",Month[w],"=ALPI_",Month[w],
"n",sep="")))
eval(parse(text=paste("PP_",Month[w],"datn=data.frame(PP_",
Month[w]," ,ONI_",Month[w]," ,PDO_",Month[w]," ,NAO_",Month[w],
" ,AMOs_",Month[w]," , NPI_",Month[w]," , ALPI",Month[w],")",sep="")))
}

#predict
for(w in 5:10){
#Modelo GB2
eval(parse(text=paste("pred",twi[i],Month[w],
"GEB=predict(mod6",twi[i],Month[w],"GEB, newdata=na.omit(PP_",
Month[w],"datn), type='response')",sep="")))
#Modelo Gamma
eval(parse(text=paste("pred",twi[i],Month[w],"GA=predict(mod4",
twi[i],Month[w],"GA, newdata=na.omit(PP_",Month[w],"datn),
type='response')", sep="")))
#Modelo Gamma Generalizada
eval(parse(text=paste("pred",twi[i],Month[w],"GG=predict(mod5",
twi[i],Month[w],"GG, newdata=na.omit(PP_",Month[w],"datn),
type='response')", sep="")))
```

A.3. Códigos R

```
eval(parse(text=paste("PP_",Month[w],"pred=na.omit(PP_",Month[w],
"datn)$PP_",Month[w], sep="")))
#names
eval(parse(text=paste("pred",twt[i],Month[w],"GAMLSS=data.frame(PP_",
Month[w],"pred,pred",twt[i],Month[w],"GEB,pred",twt[i],Month[w],"GA,
pred",twt[i],Month[w],"GG)", sep="")))
eval(parse(text=paste("names(pred",twt[i],Month[w],"GAMLSS)=c('Mes',
'predGEB','predGA','predGG')",sep="")))

setwd("C:/Resultspred")
eval(parse(text=paste("write.csv(pred",twt[i],Month[w],"GAMLSS,file= 'pred",
twt[i],Month[w],"GAMLSS.csv')",sep="")))
}
}

### GEB2 AIC, y log likelihood
eval(parse(text=paste("AIC0",twt[i],"GEB=c(AIC0",twt[i],"MayGEB,AIC0",
twt[i],"JunGEB,AIC0",twt[i],"JulGEB,AIC0",twt[i],"AgoGEB,AIC0",
twt[i],"SepGEB,AIC0",twt[i],"OctGEB)", sep="")))

eval(parse(text=paste("AIC1",twt[i],"GEB=c(AIC1",twt[i],"MayGEB,AIC1",
twt[i],"JunGEB,AIC1",twt[i],"JulGEB,AIC1",twt[i],"AgoGEB,AIC1",twt[i],
"SepGEB,AIC1",twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("AIC2",twt[i],"GEB=c(AIC2",twt[i],"MayGEB,AIC2",
twt[i],"JunGEB,AIC2",twt[i],"JulGEB,AIC2",twt[i],"AgoGEB,AIC2",twt[i],
"SepGEB,AIC2",twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("df01",twt[i],"GEB=c(df01",twt[i],"MayGEB,df01",
twt[i],"JunGEB,df01",twt[i],"JulGEB,df01",twt[i],"AgoGEB,df01",twt[i],
"SepGEB,df01",twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("df02",twt[i],"GEB=c(df02",twt[i],"MayGEB,df02",
twt[i],"JunGEB,df02",twt[i],"JulGEB,df02",twt[i],"AgoGEB,df02",twt[i],
"SepGEB,df02",twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("l1",twt[i],"GEB=c(l1",twt[i],"MayGEB,l1",twt[i],
"JunGEB,l1",twt[i],"JulGEB,l1",twt[i],"AgoGEB,l1",twt[i],"SepGEB,l1",
twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("l2",twt[i],"GEB=c(l2",twt[i],"MayGEB,l2",twt[i],
"JunGEB,l2",twt[i],"JulGEB,l2",twt[i],"AgoGEB,l2",twt[i],"SepGEB,l2",
twt[i],"OctGEB)", sep="")))
eval(parse(text=paste("l0",twt[i],"GEB=c(l0",twt[i],"MayGEB,l0",twt[i],
"JunGEB,l0",twt[i],"JulGEB,l0",twt[i],"AgoGEB,l0",twt[i],"SepGEB,l0",
twt[i],"OctGEB)", sep="")))

eval(parse(text=paste("chigs01",twt[i],"GEB=c(chigs01",twt[i],"MayGEB,
chigs01",twt[i],"JunGEB,chigs01",twt[i],"JulGEB,chigs01",twt[i],"AgoGEB,
chigs01",twt[i],"SepGEB,chigs01",twt[i],"OctGEB)", sep="")))

```

A.3. Códigos R

```
eval(parse(text=paste("chigs02",tw[t[i],"GEB=c(chigs02",tw[t[i],"MayGEB,
chigs02",tw[t[i],"JunGEB,chigs02",tw[t[i],"JulGEB,chigs02",tw[t[i],"AgoGEB,
chigs02",tw[t[i],"SepGEB,chigs02",tw[t[i],"OctGEB)", sep=""))))
```

```
eval(parse(text=paste("p01",tw[t[i],"GEB=c(p01",tw[t[i],"MayGEB,p01",tw[t[i],
"JunGEB,p01",tw[t[i],"JulGEB,p01",tw[t[i],"AgoGEB,p01",tw[t[i],"SepGEB,p01",
tw[t[i],"OctGEB)", sep="")))) #P-value
```

```
eval(parse(text=paste("p02",tw[t[i],"GEB=c(p02",tw[t[i],"MayGEB,p02",tw[t[i],
"JunGEB,p02",tw[t[i],"JulGEB,p02",tw[t[i],"AgoGEB,p02",tw[t[i],"SepGEB,p02",
tw[t[i],"OctGEB)", sep=""))))#P-value
```

#GAMMA

```
eval(parse(text=paste("AIC0",tw[t[i],"GA=c(AIC0",tw[t[i],"MayGA,AIC0",tw[t[i],
"JunGA,AIC0",tw[t[i],"JulGA,AIC0",tw[t[i],"AgoGA,AIC0",tw[t[i],"SepGA,AIC0",
tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("AIC1",tw[t[i],"GA=c(AIC1",tw[t[i],"MayGA,AIC1",tw[t[i],
"JunGA,AIC1",tw[t[i],"JulGA,AIC1",tw[t[i],"AgoGA,AIC1",tw[t[i],"SepGA,AIC1",
tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("AIC2",tw[t[i],"GA=c(AIC2",tw[t[i],"MayGA,AIC2",tw[t[i],
"JunGA,AIC2",tw[t[i],"JulGA,AIC2",tw[t[i],"AgoGA,AIC2",tw[t[i],"SepGA,AIC2",
tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("df01",tw[t[i],"GA=c(df01",tw[t[i],"MayGA,df01",tw[t[i],
"JunGA,df01",tw[t[i],"JulGA,df01",tw[t[i],"AgoGA,df01",tw[t[i],"SepGA,df01",
tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("df02",tw[t[i],"GA=c(df02",tw[t[i],"MayGA,df02",tw[t[i],
"JunGA,df02",tw[t[i],"JulGA,df02",tw[t[i],"AgoGA,df02",tw[t[i],"SepGA,df02",
tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("l1",tw[t[i],"GA=c(l1",tw[t[i],"MayGA,l1",tw[t[i],
"JunGA,l1",tw[t[i],"JulGA,l1",tw[t[i],"AgoGA,l1",tw[t[i],"SepGA,l1",tw[t[i],
"OctGA)", sep=""))))
```

```
eval(parse(text=paste("l2",tw[t[i],"GA=c(l2",tw[t[i],"MayGA,l2",tw[t[i],
"JunGA,l2",tw[t[i],"JulGA,l2",tw[t[i],"AgoGA,l2",tw[t[i],"SepGA,l2",tw[t[i],
"OctGA)", sep=""))))
```

```
eval(parse(text=paste("l0",tw[t[i],"GA=c(l0",tw[t[i],"MayGA,l0",tw[t[i],
"JunGA,l0",tw[t[i],"JulGA,l0",tw[t[i],"AgoGA,l0",tw[t[i],"SepGA,l0",tw[t[i],
"OctGA)", sep=""))))
```

```
eval(parse(text=paste("chigs01",tw[t[i],"GA=c(chigs01",tw[t[i],"MayGA,
chigs01",tw[t[i],"JunGA,chigs01",tw[t[i],"JulGA,chigs01",tw[t[i],"AgoGA,
chigs01",tw[t[i],"SepGA,chigs01",tw[t[i],"OctGA)", sep=""))))
```

```
eval(parse(text=paste("chigs02",tw[t[i],"GA=c(chigs02",tw[t[i],"MayGA,
chigs02",tw[t[i],"JunGA,chigs02",tw[t[i],"JulGA,chigs02",tw[t[i],"AgoGA,
chigs02",tw[t[i],"SepGA,chigs02",tw[t[i],"OctGA)", sep=""))))
```


A.3. Códigos R

```
eval(parse(text=paste("p01",twl[i],"GA=c(p01",twl[i],"MayGA,p01",twl[i],
"JunGA,p01",twl[i],"JulGA,p01",twl[i],"AgoGA,p01",twl[i],"SepGA,p01",
twl[i],"OctGA)", sep=""))) #P-value
eval(parse(text=paste("p02",twl[i],"GA=c(p02",twl[i],"MayGA,p02",twl[i],
"JunGA,p02",twl[i],"JulGA,p02",twl[i],"AgoGA,p02",twl[i],"SepGA,p02",
twl[i],"OctGA)", sep="")))#P-value
#GG
eval(parse(text=paste("AIC0",twl[i],"GG=c(AIC0",twl[i],"MayGG,AIC0",twl[i],
"JunGG,AIC0",twl[i],"JulGG,AIC0",twl[i],"AgoGG,AIC0",twl[i],"SepGG,AIC0",
twl[i],"OctGG)", sep="")))
eval(parse(text=paste("AIC1",twl[i],"GG=c(AIC1",twl[i],"MayGG,AIC1",twl[i],
"JunGG,AIC1",twl[i],"JulGG,AIC1",twl[i],"AgoGG,AIC1",twl[i],"SepGG,AIC1",
twl[i],"OctGG)", sep="")))
eval(parse(text=paste("AIC2",twl[i],"GG=c(AIC2",twl[i],"MayGG,AIC2",twl[i],
"JunGG,AIC2",twl[i],"JulGG,AIC2",twl[i],"AgoGG,AIC2",twl[i],"SepGG,AIC2",
twl[i],"OctGG)", sep="")))
eval(parse(text=paste("df01",twl[i],"GG=c(df01",twl[i],"MayGG,df01",twl[i],
"JunGG,df01",twl[i],"JulGG,df01",twl[i],"AgoGG,df01",twl[i],"SepGG,df01",
twl[i],"OctGG)", sep="")))
eval(parse(text=paste("df02",twl[i],"GG=c(df02",twl[i],"MayGG,df02",twl[i],
"JunGG,df02",twl[i],"JulGG,df02",twl[i],"AgoGG,df02",twl[i],"SepGG,df02",
twl[i],"OctGG)", sep="")))

eval(parse(text=paste("l1",twl[i],"GG=c(l1",twl[i],"MayGG,l1",twl[i],"JunGG,
l1",twl[i],"JulGG,l1",twl[i],"AgoGG,l1",twl[i],"SepGG,l1",twl[i],"OctGG)",
sep="")))
eval(parse(text=paste("l2",twl[i],"GG=c(l2",twl[i],"MayGG,l2",twl[i],"JunGG,
l2",twl[i],"JulGG,l2",twl[i],"AgoGG,l2",twl[i],"SepGG,l2",twl[i],"OctGG)",
sep="")))
eval(parse(text=paste("l0",twl[i],"GG=c(l0",twl[i],"MayGG,l0",twl[i],"JunGG,l0",.
twl[i],"JulGG,l0",twl[i],"AgoGG,l0",twl[i],"SepGG,l0",twl[i],"OctGG)",
sep="")))

eval(parse(text=paste("chigs01",twl[i],"GG=c(chigs01",twl[i],"MayGG,chigs01",
twl[i],"JunGG,chigs01",twl[i],"JulGG,chigs01",twl[i],"AgoGG,chigs01",twl[i],
"SepGG,chigs01",twl[i],"OctGG)", sep="")))
eval(parse(text=paste("chigs02",twl[i],"GG=c(chigs02",twl[i],"MayGG,chigs02",
twl[i],"JunGG,chigs02",twl[i],"JulGG, chigs02",twl[i],
"AgoGG,chigs02",twl[i],"SepGG,chigs02",twl[i],"OctGG)", sep="")))

eval(parse(text=paste("p01",twl[i],"GG=c(p01",twl[i],"MayGG,p01",twl[i],"JunGG,
p01",twl[i],"JulGG,p01",twl[i],"AgoGG,p01",twl[i],"SepGG,p01",twl[i],"OctGG)", sep="
eval(parse(text=paste("p02",twl[i],"GG=c(p02",twl[i],"MayGG,p02",twl[i],"JunGG,
p02",twl[i],"JulGG,p02",twl[i],"AgoGG,p02",twl[i],"SepGG,p02",twl[i],"OctGG)",
sep="")))#P-value
```

A.3. Códigos R

```
eval(parse(text=paste("est",twt[i],"GAMLSS=data.frame(Est[i,3],Month[5:10],
AIC0",twt[i],"GEB,AIC1",twt[i],"GEB,AIC2",twt[i],"GEB, df01",twt[i],
"GEB,df02",twt[i],"GEB,l0",twt[i],"GEB,l1",twt[i],"GEB,l2",
twt[i],"GEB,chiqs01",twt[i],"GEB,chiqs02",twt[i],"GEB,
p01",twt[i],"GEB,p02",twt[i],"GEB,AIC0",twt[i],"GA,AIC1",twt[i],"GA,
AIC2",twt[i],"GA,df01",twt[i],"GA,df02",twt[i],"GA,l0",twt[i],"GA, l1",twt[i],
"GA,l2",twt[i],"GA, chiqs01",twt[i],"GA,chiqs02",twt[i],"GA,p01",twt[i],"GA,
p02",twt[i],"GA,AIC0",twt[i],"GG, AIC1",twt[i],"GG, AIC2",twt[i],
"GG, df01",twt[i],"GG,df02",twt[i],"GG,l0",twt[i],"GG,l1",twt[i],"GG,
l2",twt[i],"GG,chiqs01",twt[i],"GG,chiqs02",twt[i],"GG,p01",twt[i],"GG,
p02",twt[i],"GG)", sep=""))))

eval(parse(text=paste("names(est",twt[i],"GAMLSS) <- c('Est','Mes',
'AIC0GEB', 'AIC1GEB','AIC2GEB', 'df01GEB', 'df02GEB', 'l0GEB', 'l1GEB',
'l2GEB', 'chisq01GEB', 'chisq02GEB', 'p01GEB','p02GEB','AIC0GA', 'AIC1GA',
'AIC2GA', 'df01GA','df02GA','l0GA', 'l1GA', 'l2GA', 'chisq01GA', 'chisq02GA',
'p01GA','p02GA','AIC0GG', 'AIC1GG', 'AIC2GG', 'df01GG','df02GG',
'l0GG', 'l1GG', 'l2GG', 'chisq01GG','chisq02GG','p01GG','p02GG')"
, sep=""))))

#Using rbind() function to insert above observation
eval(parse(text=paste("EstModelGAMLSS= rbind(EstModelGAMLSS, est",twt[i],
"GAMLSS)", sep=""))))
}
write.csv(EstModelGAMLSS, file="EstModelGAMLSS.csv")
```

APÉNDICE B

DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS UTILIZADAS EN EL PRESENTE ESTUDIO

Cuadro B.1: Estaciones analizadas en el presente estudio

ESTACIÓN	NOMBRE	ESTADO
5001	AGUA NUEVA	COAHUILA DE ZARAGOZA
5002	ALLENDE (SMN)	COAHUILA DE ZARAGOZA
5003	ARTEAGA (SMN)	COAHUILA DE ZARAGOZA
5004	BAJIO DE AHUICHILA	COAHUILA DE ZARAGOZA
5005	CANDELA (DGE)	COAHUILA DE ZARAGOZA
5007	CONCORDIA	COAHUILA DE ZARAGOZA
5008	CONCHOS	COAHUILA DE ZARAGOZA
5009	CUATRO CIENEGAS (DGE)	COAHUILA DE ZARAGOZA
5011	EJIDO REATA	COAHUILA DE ZARAGOZA
5013	EJIDO SAN MIGUEL	COAHUILA DE ZARAGOZA
5016	GENERAL CEPEDA	COAHUILA DE ZARAGOZA
5018	LAS NIEVES	COAHUILA DE ZARAGOZA
5019	MONCLOVA (OBS)	COAHUILA DE ZARAGOZA
5020	MUZQUIZ (DGE)	COAHUILA DE ZARAGOZA
5021	NUEVA ROSITA	COAHUILA DE ZARAGOZA
5022	OCAMPO	COAHUILA DE ZARAGOZA
5023	PALESTINA (DGE)	COAHUILA DE ZARAGOZA
5024	PARRAS	COAHUILA DE ZARAGOZA
5025	PIEDRAS NEGRAS (OBS)	COAHUILA DE ZARAGOZA
5026	PRESA COYOTE	COAHUILA DE ZARAGOZA
5027	EL CUIJE	COAHUILA DE ZARAGOZA

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
5028	PRESA DE GUADALUPE	COAHUILA DE ZARAGOZA
5029	PRESA LA FLOR	COAHUILA DE ZARAGOZA
5030	PRESA VENUSTIANO CARRANZA	COAHUILA DE ZARAGOZA
5031	PROGRESO	COAHUILA DE ZARAGOZA
5032	RAMOS ARIZPE (SMN)	COAHUILA DE ZARAGOZA
5033	SABINAS (DGE)	COAHUILA DE ZARAGOZA
5034	SALTILLO (OBS)	COAHUILA DE ZARAGOZA
5035	SAN ANTONIO LAS ALAZANAS (DGE)	COAHUILA DE ZARAGOZA
5036	SAN PEDRO	COAHUILA DE ZARAGOZA
5037	SAN VICENTE	COAHUILA DE ZARAGOZA
5038	SANTA TERESA	COAHUILA DE ZARAGOZA
5039	SIERRA MOJADA	COAHUILA DE ZARAGOZA
5040	TORREON (OBS)	COAHUILA DE ZARAGOZA
5041	VIESCA (DGE)	COAHUILA DE ZARAGOZA
5042	ZARAGOZA (SMN)	COAHUILA DE ZARAGOZA
5045	JUAREZ	COAHUILA DE ZARAGOZA
5047	MONCLOVA (DGE)	COAHUILA DE ZARAGOZA
5048	SALTILLO (DGE)	COAHUILA DE ZARAGOZA
5049	SAN ANTONIO LAS ALAZANAS (SMN)	COAHUILA DE ZARAGOZA
5050	SAN BUENAVENTURA (SMN)	COAHUILA DE ZARAGOZA
5058	LA ROSITA	COAHUILA DE ZARAGOZA
5063	E.T.A. 110 ALLENDE	COAHUILA DE ZARAGOZA
5066	SABINAS (SMN)	COAHUILA DE ZARAGOZA
5068	PALESTINA (SMN)	COAHUILA DE ZARAGOZA
5069	MUZQUIZ (SMN)	COAHUILA DE ZARAGOZA
5074	ZARAGOZA (DGE)	COAHUILA DE ZARAGOZA
5081	CARNEROS	COAHUILA DE ZARAGOZA
5085	PRESA CENTENARIO	COAHUILA DE ZARAGOZA
5086	PRESA SAN MIGUEL	COAHUILA DE ZARAGOZA
5135	EL GUAJE	COAHUILA DE ZARAGOZA
5136	LAS HORMIGAS	COAHUILA DE ZARAGOZA
5139	EMILIANO ZAPATA	COAHUILA DE ZARAGOZA
5140	RAMOS ARIZPE (DGE)	COAHUILA DE ZARAGOZA
5141	GOMEZ FARIAS	COAHUILA DE ZARAGOZA
5142	HIPOLITO	COAHUILA DE ZARAGOZA
5144	SANTA TERESA DE SOFIA	COAHUILA DE ZARAGOZA
5145	SAN JUAN DE LA VAQUERIA	COAHUILA DE ZARAGOZA
5146	HUACHICHIL	COAHUILA DE ZARAGOZA
5147	EJIDO PRIMERO DE MAYO	COAHUILA DE ZARAGOZA
5150	ABASOLO	COAHUILA DE ZARAGOZA
5151	ALTO DE NORIAS	COAHUILA DE ZARAGOZA
5152	BAJAN	COAHUILA DE ZARAGOZA

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
5153	CASTAÑOS (DGE)	COAHUILA DE ZARAGOZA
5155	LAMADRID	COAHUILA DE ZARAGOZA
5156	PALAU	COAHUILA DE ZARAGOZA
5157	SAN FRANCISCO DEL VALLE	COAHUILA DE ZARAGOZA
5158	EL TANQUITO	COAHUILA DE ZARAGOZA
5159	ACATITA	COAHUILA DE ZARAGOZA
5162	DOS DE ABRIL	COAHUILA DE ZARAGOZA
5164	SAN FRANCISCO NADADORES	COAHUILA DE ZARAGOZA
5166	LAS ESPERANZAS	COAHUILA DE ZARAGOZA
5167	EL MARQUEZ	COAHUILA DE ZARAGOZA
5168	NOCHE BUENA	COAHUILA DE ZARAGOZA
5169	RODRIGUEZ	COAHUILA DE ZARAGOZA
5170	LA ROSA	COAHUILA DE ZARAGOZA
5171	SACRAMENTO	COAHUILA DE ZARAGOZA
5174	EL TUNAL	COAHUILA DE ZARAGOZA
5175	LA VENTURA	COAHUILA DE ZARAGOZA
5176	JAME	COAHUILA DE ZARAGOZA
5178	TEJABAN DE LA ROSITA	COAHUILA DE ZARAGOZA
5179	ESTANQUE DE LEON	COAHUILA DE ZARAGOZA
5180	FRANCISCO I. MADERO	COAHUILA DE ZARAGOZA
5181	EL SOL	COAHUILA DE ZARAGOZA
5184	TANQUE AGUILEREÑO	COAHUILA DE ZARAGOZA
5186	CABECERAS	COAHUILA DE ZARAGOZA
10001	ATOTONILCO	DURANGO
10004	CAÑÓN FERNANDEZ	DURANGO
10005	CEBALLOS	DURANGO
10006	CENDRADILLAS	DURANGO
10007	CIENEGA DE ESCOBAR	DURANGO
10008	CINCO DE MAYO	DURANGO
10009	CIUDAD LERDO (OBS)	DURANGO
10010	COLONIA IGNACIO ZARAGOZA	DURANGO
10011	COLONIA INSURGENTES	DURANGO
10012	CUENCAME	DURANGO
10016	CHINACATES	DURANGO
10017	DURANGO (OBS)	DURANGO
10020	EL DERRAME	DURANGO
10021	EL PALMITO	DURANGO
10022	EL PINO	DURANGO
10023	EL PUEBLITO	DURANGO
10026	EL TARAHUMAR	DURANGO
10027	FRANCISCO I. MADERO	DURANGO
10028	EL CUARTO	DURANGO

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
10029	GUANACEVI (SMN)	DURANGO
10030	GUADALUPE VICTORIA (DGE)	DURANGO
10035	J. SALOME ACOSTA	DURANGO
10045	MAPIMI	DURANGO
10049	NAZAS	DURANGO
10051	OTINAPA	DURANGO
10052	PANUCO DE CORONADO	DURANGO
10053	PEÑOLES	DURANGO
10054	PEÑA DEL AGUILA	DURANGO
10055	PEDRICEÑA	DURANGO
10056	PEÑON BLANCO (SMN)	DURANGO
10060	RODEO (SMN)	DURANGO
10061	ROSARIO	DURANGO
10062	SAN ANTONIO	DURANGO
10063	SAN BARTOLO	DURANGO
10067	SAN JUAN DE GUADALUPE (SMN)	DURANGO
10068	SAN JUAN DEL RIO	DURANGO
10069	SAN LUIS DEL CORDERO (SMN)	DURANGO
10070	SAN MARCOS	DURANGO
10072	SAN PEDRO DEL GALLO (SMN)	DURANGO
10074	SANTA CLARA	DURANGO
10075	SANTA MARIA DEL ORO	DURANGO
10076	SANTIAGO BAYACORA	DURANGO
10077	SANTIAGO PAPASQUIARO (DGE)	DURANGO
10078	SARDINAS	DURANGO
10080	SIMON BOLIVAR	DURANGO
10083	TEJAMEN	DURANGO
10084	TEPEHUANES (SMN)	DURANGO
10085	TLAHUALILO	DURANGO
10089	VILLA HIDALGO (SMN)	DURANGO
10090	CANATLAN (DGE)	DURANGO
10092	DURANGO (DGE)	DURANGO
10098	RODEO (DGE)	DURANGO
10099	SAN JUAN DE GUADALUPE (DGE)	DURANGO
10100	SANTIAGO PAPASQUIARO (SMN)	DURANGO
10102	GUATIMAPE (SMN)	DURANGO
10103	SANTA BARBARA (DGE)	DURANGO
10108	CIUDAD LERDO (DGE)	DURANGO
10124	LA FLOR	DURANGO
10125	LA ROSILLA	DURANGO
10128	VILLA HIDALGO (DGE)	DURANGO
10129	CONETO DE COMONFORT	DURANGO

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
10131	PEÑON BLANCO (DGE)	DURANGO
10132	SAN LUIS DEL CORDERO (DGE)	DURANGO
10136	DOCE DE DICIEMBRE	DURANGO
10137	GUATIMAPE (DGE)	DURANGO
10138	SAN BERNARDO	DURANGO
10139	AGUA PUERCA	DURANGO
10140	LA CADENA	DURANGO
10141	CANUTILLO	DURANGO
10142	EL CASCO	DURANGO
10143	INDE	DURANGO
10144	EL MIRADOR	DURANGO
10146	YERBANIS	DURANGO
10147	EL ZAPE	DURANGO
10149	GENERAL ESCOBEDO	DURANGO
10150	LUIS MOYA	DURANGO
10161	YERMO	DURANGO
10163	VILLA JUAREZ (CFE)	DURANGO
10164	LA FLOR DEL DESIERTO	DURANGO
10165	LABORATORIO DEL DESIERTO	DURANGO
10170	C.B.T.A. 047 LERDO	DURANGO
10188	CEVAG	DURANGO
13012	HUICHAPAN	HIDALGO
13013	IXMIQUILPAN (SMN)	HIDALGO
13053	TECOZAUTLA	HIDALGO
13063	PRESA BOQUILLA TECOLOTE	HIDALGO
13088	TASQUILLO	HIDALGO
13120	CAPULA	HIDALGO
19003	ALLENDE	NUEVO LEON
19004	APODACA	NUEVO LEON
19006	BUSTAMANTE	NUEVO LEON
19007	CABEZONES	NUEVO LEON
19008	CADEREYTA	NUEVO LEON
19010	CERRALVO (DGE)	NUEVO LEON
19011	CERRO PRIETO	NUEVO LEON
19012	CIENEGA DE FLORES	NUEVO LEON
19013	CIENEGA DEL TORO	NUEVO LEON
19015	EL CERRITO	NUEVO LEON
19019	EL REALITO	NUEVO LEON
19020	EL POTOSI	NUEVO LEON
19021	GARZA AYALA	NUEVO LEON
19025	HIGUERAS (SMN)	NUEVO LEON
19026	ICAMOLE	NUEVO LEON

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
19028	LAMPAZOS (SMN)	NUEVO LEON
19029	LA ARENA	NUEVO LEON
19032	CARBONERA	NUEVO LEON
19034	PABLILLO (SMN)	NUEVO LEON
19035	CAMACHO	NUEVO LEON
19036	LA POPA	NUEVO LEON
19037	LAS PRESAS	NUEVO LEON
19042	LOS RAMONES	NUEVO LEON
19044	MAMULIQUE	NUEVO LEON
19045	MINA	NUEVO LEON
19046	MIER Y NORIEGA (SMN)	NUEVO LEON
19048	MONTEMORELOS	NUEVO LEON
19049	MONTERREY	NUEVO LEON
19050	SAN JOSE DE RAICES	NUEVO LEON
19052	MONTERREY (OBS)	NUEVO LEON
19054	RINCONADA	NUEVO LEON
19055	SALINILLAS	NUEVO LEON
19056	SAN JUAN	NUEVO LEON
19057	SAN RAFAEL	NUEVO LEON
19058	SANTA CATARINA	NUEVO LEON
19059	SANTA ROSA	NUEVO LEON
19060	SOMBRERETILLO	NUEVO LEON
19061	TOPO CHICO	NUEVO LEON
19063	VALLECILLO (DGE)	NUEVO LEON
19065	SANTIAGO	NUEVO LEON
19067	EL RUCIO	NUEVO LEON
19068	DOCTOR ARROYO (SMN)	NUEVO LEON
19069	LA BOCA	NUEVO LEON
19070	LAMPAZOS (DGE)	NUEVO LEON
19075	DOCTOR ARROYO II (DGE)	NUEVO LEON
19077	VALLECILLO (SMN)	NUEVO LEON
19079	EL REFUGIO DE LOS IBARRA	NUEVO LEON
19091	PABLILLO (DGE)	NUEVO LEON
19093	SAN JUANITO DE RESENDIZ	NUEVO LEON
19096	LA HUASTEQUITA	NUEVO LEON
19099	CERRALVO (SMN)	NUEVO LEON
19100	SAN FRANCISCO LA CARRERA	NUEVO LEON
19104	LA ESCONDIDA	NUEVO LEON
19105	DOCTOR GONZALEZ	NUEVO LEON
19107	SAN NICOLAS	NUEVO LEON
19108	SAN CRISTOBAL PURISIMA	NUEVO LEON
19109	UÑA DE GATO	NUEVO LEON

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
19111	LA ASCENCION	NUEVO LEON
19112	BENITEZ	NUEVO LEON
19115	EL CUIJE	NUEVO LEON
19117	EJIDO MARIN	NUEVO LEON
19119	ESPINAZO	NUEVO LEON
19121	GATOS GÑEROS	NUEVO LEON
19123	GRUTAS DE GARCIA	NUEVO LEON
19124	HIGUERAS (DGE)	NUEVO LEON
19126	LA LAJA	NUEVO LEON
19128	OBREGON	NUEVO LEON
19129	EL PEÑUELO	NUEVO LEON
19131	PUERTO DEL EBANO	NUEVO LEON
19133	SABINAS HIDALGO	NUEVO LEON
19134	SALINAS VICTORIA	NUEVO LEON
19135	SAN FRANCISCO DE BERLANGA	NUEVO LEON
19136	SAN ISIDRO	NUEVO LEON
19137	SAN JORGE	NUEVO LEON
19138	SANTA ANA	NUEVO LEON
19140	TEPEHUAJE	NUEVO LEON
19141	VILLALDAMA	NUEVO LEON
19143	LA CARDONA	NUEVO LEON
19144	CIENEGUITAS Y CRUCITAS	NUEVO LEON
19146	CONGREGACION CALLES	NUEVO LEON
19147	LAS CRUCITAS	NUEVO LEON
19151	LAS MARGARITAS	NUEVO LEON
19154	EL POPOTE	NUEVO LEON
19158	RANCHO DE GOMAS	NUEVO LEON
19159	SAN ANTONIO PEÑA NEVADA	NUEVO LEON
19160	SAN IGNACIO DE TEXAS	NUEVO LEON
19163	LAS BRISAS	NUEVO LEON
19165	CHUPADEROS DEL INDIO	NUEVO LEON
19166	EJIDO HORCONES	NUEVO LEON
19170	EL HOJASE	NUEVO LEON
19171	LAMPACITOS	NUEVO LEON
19172	LAS MONITAS	NUEVO LEON
19173	PALMITOS (GE)	NUEVO LEON
19174	SAN BARTOLO	NUEVO LEON
19178	SIERRA MORENA	NUEVO LEON
19180	SAN ANTONIO EL SALERO	NUEVO LEON
19181	SAN ISIDRO DE CIENEGA	NUEVO LEON
19182	SAN ROBERTO	NUEVO LEON
24004	ARMADILLO DE LOS INFANTE	SAN LUIS POTOSI

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
24007	NORMAL DEL DESIERTO	SAN LUIS POTOSI
24008	CERRITOS	SAN LUIS POTOSI
24013	COLONIA ALVARO OBREGON	SAN LUIS POTOSI
24019	EL ESTRIBO	SAN LUIS POTOSI
24021	EL GRITO	SAN LUIS POTOSI
24022	EL HUIZACHE	SAN LUIS POTOSI
24024	EL PEAJE	SAN LUIS POTOSI
24032	GUADALCAZAR	SAN LUIS POTOSI
24033	LA MAROMA	SAN LUIS POTOSI
24034	LA SALITRERA	SAN LUIS POTOSI
24038	LOS PILARES	SAN LUIS POTOSI
24040	MATEHUALA (SMN)	SAN LUIS POTOSI
24041	MATEHUALA (DGE)	SAN LUIS POTOSI
24042	MEXQUITIC	SAN LUIS POTOSI
24044	MOCTEZUMA (DGE)	SAN LUIS POTOSI
24045	NOGAL OSCURO	SAN LUIS POTOSI
24046	OJO CALIENTE	SAN LUIS POTOSI
24048	VALLEJO	SAN LUIS POTOSI
24050	PAREDES	SAN LUIS POTOSI
24051	PASO DE SAN ANTONIO	SAN LUIS POTOSI
24052	PASTORA	SAN LUIS POTOSI
24055	PEÑON BLANCO	SAN LUIS POTOSI
24057	PRESA DE GUADALUPE	SAN LUIS POTOSI
24058	PRESA PALOMAS	SAN LUIS POTOSI
24059	VILLA DE RAMOS II	SAN LUIS POTOSI
24061	RINCON DEL PORVENIR	SAN LUIS POTOSI
24062	RIOVERDE (OBS)	SAN LUIS POTOSI
24066	SAN FRANCISCO	SAN LUIS POTOSI
24067	SAN JOSE ALBURQUERQUE	SAN LUIS POTOSI
24069	SAN LUIS POTOSI (DGE)	SAN LUIS POTOSI
24070	SAN LUIS POTOSI (OBS)	SAN LUIS POTOSI
24071	SAN NICOLAS TOLENTINO	SAN LUIS POTOSI
24073	LA REFORMA	SAN LUIS POTOSI
24074	SANTA MARIA DEL REFUGIO	SAN LUIS POTOSI
24075	SANTA MARIA DEL RIO (DGE)	SAN LUIS POTOSI
24077	SANTO DOMINGO	SAN LUIS POTOSI
24078	SANTIAGO	SAN LUIS POTOSI
24081	SOLEDAD DE GRACIANO	SAN LUIS POTOSI
24093	TIERRA NUEVA	SAN LUIS POTOSI
24094	VANEGAS	SAN LUIS POTOSI
24096	VENADO	SAN LUIS POTOSI
24097	VIGAS	SAN LUIS POTOSI

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
24098	EL MEZQUITE	SAN LUIS POTOSI
24100	VILLA DE ARRIAGA (DGE)	SAN LUIS POTOSI
24101	VILLA DE REYES	SAN LUIS POTOSI
24102	VILLA HIDALGO	SAN LUIS POTOSI
24103	VILLA JUAREZ	SAN LUIS POTOSI
24106	ZARAGOZA	SAN LUIS POTOSI
24109	MOCTEZUMA (SMN)	SAN LUIS POTOSI
24110	OJO DE AGUA SECO	SAN LUIS POTOSI
24111	SAN LUIS POTOSI (SMN)	SAN LUIS POTOSI
24114	RIOVERDE (DGE)	SAN LUIS POTOSI
24130	GRANJENAL	SAN LUIS POTOSI
24142	LA PRESA	SAN LUIS POTOSI
24144	LA CARDONCITA	SAN LUIS POTOSI
24145	LAGUNA SECA	SAN LUIS POTOSI
24146	LA VICTORIA	SAN LUIS POTOSI
24148	SALINAS DE HIDALGO	SAN LUIS POTOSI
24150	GUANAME	SAN LUIS POTOSI
24151	SAN JUAN DEL SALADO	SAN LUIS POTOSI
24152	SAUZ DE CALERA	SAN LUIS POTOSI
24153	COLONIA BENITO JUAREZ	SAN LUIS POTOSI
24154	SAN FRANCISCO II	SAN LUIS POTOSI
24157	ZARAGOZA	SAN LUIS POTOSI
24158	CHARCAS (SMN)	SAN LUIS POTOSI
24159	LA MORITA	SAN LUIS POTOSI
24160	COYOTILLOS	SAN LUIS POTOSI
24161	LA HERRRADURA	SAN LUIS POTOSI
24162	EL CARMEN	SAN LUIS POTOSI
24163	BLEDOS	SAN LUIS POTOSI
24164	LLANO DEL CARMEN	SAN LUIS POTOSI
24165	SAN JOSE DE CORONADOS	SAN LUIS POTOSI
24166	VILLA DE RAMOS I	SAN LUIS POTOSI
24168	BUENAVISTA	SAN LUIS POTOSI
24170	EL CHARCO	SAN LUIS POTOSI
24171	HUIZACHAL	SAN LUIS POTOSI
24172	MANANTIAL DE MEDIA LUNA	SAN LUIS POTOSI
24173	PRESA ALVARO OBREGON	SAN LUIS POTOSI
24175	EL SALADO	SAN LUIS POTOSI
24176	SAN JUAN DE TUZAL	SAN LUIS POTOSI
24177	SANTA CATARINA	SAN LUIS POTOSI
24179	XOCONOXTLE	SAN LUIS POTOSI
24180	CAÑADA VERDE	SAN LUIS POTOSI
24181	EL ASTILLERO	SAN LUIS POTOSI

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
24187	TEPEYAC	SAN LUIS POTOSI
24188	CORONADO	SAN LUIS POTOSI
24189	EL HOSPITAL	SAN LUIS POTOSI
24190	LA LIBERTAD	SAN LUIS POTOSI
24191	SAN ANTONIO DEL MEZQUITE	SAN LUIS POTOSI
24192	SAN FRANCISCO DE LA DICHA	SAN LUIS POTOSI
24193	SAN JOSE DE TAPANCO	SAN LUIS POTOSI
24194	SAN RAFAEL	SAN LUIS POTOSI
24195	LAS TABLAS	SAN LUIS POTOSI
24196	EL TORO	SAN LUIS POTOSI
28007	BARRANCO AZUL	TAMAULIPAS
28010	BUSTAMANTE	TAMAULIPAS
28019	CRUILLAS	TAMAULIPAS
28021	CORRALEJO	TAMAULIPAS
28024	CAÑON DEL DIABLO	TAMAULIPAS
28034	FRANCISCO ZORRILLA	TAMAULIPAS
28037	HIDALGO (SMN)	TAMAULIPAS
28038	HIDALGO (DGE)	TAMAULIPAS
28039	JAUMAVE (SMN)	TAMAULIPAS
28040	JAUMAVE (DGE)	TAMAULIPAS
28047	LA LOBA	TAMAULIPAS
28050	LA SONADORA	TAMAULIPAS
28059	MAGUEYES	TAMAULIPAS
28060	VILLA MAINERO	TAMAULIPAS
28063	MIQUIHUANA	TAMAULIPAS
28071	PALMILLAS	TAMAULIPAS
28075	PLAN DE AYALA	TAMAULIPAS
28084	SAN CARLOS	TAMAULIPAS
28089	SAN JOSE DEL VERDE	TAMAULIPAS
28091	SAN PABLO	TAMAULIPAS
28094	SAN NICOLAS	TAMAULIPAS
28096	SAN VICENTE	TAMAULIPAS
28114	TULA	TAMAULIPAS
28115	LOS UVALLE	TAMAULIPAS
28116	CIUDAD VICTORIA (DGE)	TAMAULIPAS
28117	VILLAGRAN (DGE)	TAMAULIPAS
28118	VILLAGRAN (SMN)	TAMAULIPAS
28148	EL BARRETAL II	TAMAULIPAS
28150	LA ALBERCA	TAMAULIPAS
28165	CIUDAD VICTORIA (OBS)	TAMAULIPAS
28176	LAS ANTONIAS	TAMAULIPAS
28179	CARRIZOS	TAMAULIPAS

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
28182	LA LIBERTAD	TAMAULIPAS
28183	MAGDALENO AGUILAR	TAMAULIPAS
28184	MARIANO ESCOBEDO	TAMAULIPAS
28185	MARIA TERESA	TAMAULIPAS
28189	PEDRO RUIZ MOLINA	TAMAULIPAS
28193	LA REFORMA	TAMAULIPAS
28194	SAN ISIDRO	TAMAULIPAS
28197	SAN JOSE DE LAS FLORES	TAMAULIPAS
28198	GARZA VALDEZ	TAMAULIPAS
28199	GUADALUPE	TAMAULIPAS
28202	LAZARO CARDENAS	TAMAULIPAS
28209	CONRADO CASTILLO	TAMAULIPAS
28214	LUCIO BLANCO	TAMAULIPAS
28218	LA BOCA	TAMAULIPAS
28264	EL FUERTE	TAMAULIPAS
14103	OJUELOS DE JALISCO (SMN)	JALISCO
14179	OJUELOS DE JALISCO (DGE)	JALISCO
11008	CAÑADA DE GONZALEZ	GUANAJUATO
11011	CINCO SEÑORES	GUANAJUATO
11015	CHARCAS	GUANAJUATO
11016	DOLORES HIDALGO (DGE)	GUANAJUATO
11017	DOLORES HIDALGO (SMN)	GUANAJUATO
11026	HACIENDA SAN JUAN	GUANAJUATO
11030	JARAL DE BERRIOS	GUANAJUATO
11033	LA BEGOÑA	GUANAJUATO
11037	LAS MESAS	GUANAJUATO
11042	LOS RODRIGUEZ	GUANAJUATO
11043	LOURDES	GUANAJUATO
11046	MINAS DE MAGUEY	GUANAJUATO
11049	NUEVO VALLE MORENO	GUANAJUATO
11050	OCAMPO	GUANAJUATO
11051	PEÑUELITAS	GUANAJUATO
11053	POZOS	GUANAJUATO
11057	RIO LAJAS	GUANAJUATO
11060	SALVATIERRA	GUANAJUATO
11061	SAN ANTON	GUANAJUATO
11062	SAN ANTONIO DE LOS MARTINEZ	GUANAJUATO
11063	SAN CRISTOBAL	GUANAJUATO
11064	SAN DIEGO DE LA UNION	GUANAJUATO
11065	SAN FELIPE (DGE)	GUANAJUATO
11066	SAN JOSE ITURBIDE (SMN)	GUANAJUATO
11067	SAN JUAN DE LOS LLANOS	GUANAJUATO

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
11069	SAN PEDRO DE LOS ALMOLOYA	GUANAJUATO
11080	VILLA DOCTOR MORA	GUANAJUATO
11081	VILLA VICTORIA (SMN)	GUANAJUATO
11082	VILLA VICTORIA (DGE)	GUANAJUATO
11096	SALAMANCA	GUANAJUATO
11107	LA QUEMADA	GUANAJUATO
11109	SAN FELIPE (SMN)	GUANAJUATO
11117	LOBOS	GUANAJUATO
11121	EL PINILLO	GUANAJUATO
11131	LAS TROJES	GUANAJUATO
11140	EL CARBON	GUANAJUATO
11155	CORRAL DE PIEDRAS	GUANAJUATO
11161	EL VERGEL	GUANAJUATO
11167	SAN J. P. DE ARRIBA	GUANAJUATO
11168	SAN JUAN TEMASCATIO	GUANAJUATO
22003	CAMPO EXPERIMENTAL CADEREYTA	QUERETARO
22012	PEÑAMILLER (SMN)	QUERETARO
22017	TOLIMAN	QUERETARO
22021	CADEREYTA DE MONTES	QUERETARO
22026	COLON	QUERETARO
22035	VIZARRON	QUERETARO
22051	EL COMEDERO	QUERETARO
22054	EL SALITRE	QUERETARO
22056	HIGUERILLAS	QUERETARO
22057	PEÑAMILLER (DGE)	QUERETARO
22062	GUILLEN	QUERETARO
32001	AGUA NUEVA	ZACATECAS
32003	CALERA	ZACATECAS
32004	CAMACHO (SMN)	ZACATECAS
32005	CAÑITAS DE FELIPE PESCADOR	ZACATECAS
32006	EL CAZADERO	ZACATECAS
32007	CEDROS	ZACATECAS
32010	CAOPAS	ZACATECAS
32011	CONCEPCION DE LA NORMA	ZACATECAS
32015	EL RUSIO	ZACATECAS
32018	EL SAUZ	ZACATECAS
32020	FRESNILLO	ZACATECAS
32021	COLONIA GONZALEZ ORTEGA	ZACATECAS
32022	GRUÑIDORA	ZACATECAS
32023	GUADALUPE DE LAS CORRIENTES	ZACATECAS
32024	GUADALUPE VICTORIA	ZACATECAS
32028	JUAN ALDAMA	ZACATECAS
32034	PUERTO SAN FRANCISCO	ZACATECAS

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
32036	MAZAPIL	ZACATECAS
32038	NIEVES	ZACATECAS
32040	NUEVO MERCURIO	ZACATECAS
32041	OJOCALIENTE	ZACATECAS
32045	RIO GRANDE (SMN)	ZACATECAS
32046	SAIN ALTO	ZACATECAS
32047	SAN ANTONIO DEL CIPRES	ZACATECAS
32048	SAN BENITO	ZACATECAS
32049	SAN FRANCISCO (SMN)	ZACATECAS
32050	SAN GIL	ZACATECAS
32052	SAN RAFAEL	ZACATECAS
32058	TRANCOSO	ZACATECAS
32059	VILLA DE COS (SMN)	ZACATECAS
32061	VILLA HIDALGO	ZACATECAS
32068	PINOS (SMN)	ZACATECAS
32071	VILLA DE COS (DGE)	ZACATECAS
32076	COLONIA GREVER LA COLORADA	ZACATECAS
32078	SAN TIBURCIO (DGE)	ZACATECAS
32084	SAN ANDRES	ZACATECAS
32087	CONCEPCION DEL ORO	ZACATECAS
32093	EL ARENAL	ZACATECAS
32107	SIERRA HERMOSA	ZACATECAS
32110	COLONIA GREVER PURISIMA SIFUENTES	ZACATECAS
32114	VILLA GONZALEZ ORTEGA	ZACATECAS
32118	LOS CAMPOS	ZACATECAS
32126	PALMILLAS	ZACATECAS
32131	SAN GERONIMO	ZACATECAS
32137	CHICHIMEQUILLAS	ZACATECAS
32141	EL SALVADOR	ZACATECAS
32142	TIERRA Y LIBERTAD	ZACATECAS
32144	SAN FRANCISCO (DGE)	ZACATECAS
32177	NUEVO TAMPICO	ZACATECAS
32187	ESPIRITU SANTO	ZACATECAS
8001	ASCENSION (SMN)	CHIHUAHUA
8004	BACHINIVA	CHIHUAHUA
8005	BALLEZA	CHIHUAHUA
8006	BANDERAS	CHIHUAHUA
8008	BAVICORA	CHIHUAHUA
8010	SAN BUENAVENTURA	CHIHUAHUA
8019	MEOQUI (SMN)	CHIHUAHUA
8021	CARICHI	CHIHUAHUA
8025	CAMARGO (SMN)	CHIHUAHUA
8026	CUAUHTEMOC	CHIHUAHUA

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
8027	DELICIAS (SMN)	CHIHUAHUA
8028	GUERRERO (SMN)	CHIHUAHUA
8029	JIMENEZ (SMN)	CHIHUAHUA
8030	JUAREZ (SMN)	CHIHUAHUA
8031	OJINAGA (SMN)	CHIHUAHUA
8032	COLONIA ANAHUAC	CHIHUAHUA
8044	DELICIAS (DGE)	CHIHUAHUA
8048	EL CUERVO	CHIHUAHUA
8049	LUIS L. LEON	CHIHUAHUA
8050	EL MAGUEY	CHIHUAHUA
8057	EL SITIO	CHIHUAHUA
8058	EL TERRERO	CHIHUAHUA
8059	EL TINTERO	CHIHUAHUA
8062	ESCALON (DGE)	CHIHUAHUA
8064	FALOMIR	CHIHUAHUA
8066	GALEANA	CHIHUAHUA
8067	GALLEGOS	CHIHUAHUA
8072	GUADALUPE	CHIHUAHUA
8074	GUAPOCA (CFE)	CHIHUAHUA
8076	GUERRERO (DGE)	CHIHUAHUA
8077	GUZMAN	CHIHUAHUA
8078	PRESA PARRAL	CHIHUAHUA
8080	JANOS (SMN)	CHIHUAHUA
8081	JIMENEZ (DGE)	CHIHUAHUA
8084	ASCENSION (DGE)	CHIHUAHUA
8085	LA BOQUILLA	CHIHUAHUA
8090	LA JUNTA	CHIHUAHUA
8091	LA TRASQUILA	CHIHUAHUA
8092	LAS BURRAS	CHIHUAHUA
8095	LAZARO CARDENAS	CHIHUAHUA
8096	LOPEZ MATEOS	CHIHUAHUA
8097	MADERA	CHIHUAHUA
8100	MANUEL BENAVIDES	CHIHUAHUA
8102	MEOQUI (DGE)	CHIHUAHUA
8103	MESA DEL HURACAN	CHIHUAHUA
8104	NAMIQUIPA	CHIHUAHUA
8108	OJO CALIENTE	CHIHUAHUA
8109	CHIHUAHUA PALACIO DE GOBIERNO	CHIHUAHUA
8110	PALOMAS	CHIHUAHUA
8111	PARRITA	CHIHUAHUA
8112	POSTA ZOOTECNICA	CHIHUAHUA
8118	RANCHO EL CUARENTA	CHIHUAHUA

**B. DESCRIPCIÓN DE LAS ESTACIONES CLIMATOLÓGICAS
UTILIZADAS EN EL PRESENTE ESTUDIO**

ESTACIÓN	NOMBRE	ESTADO
8121	SAMALAYUCA	CHIHUAHUA
8122	SAN ANTONIO	CHIHUAHUA
8123	SAN FRANCISCO DE BORJA (SMN)	CHIHUAHUA
8127	SAN LORENZO	CHIHUAHUA
8129	SANTA ANITA	CHIHUAHUA
8135	SAUCILLO	CHIHUAHUA
8139	SUECO	CHIHUAHUA
8142	TEMOSACHI (OBS)	CHIHUAHUA
8146	TRES OJITOS	CHIHUAHUA
8151	VALLE DE ALLENDE (SMN)	CHIHUAHUA
8154	VICTORIA	CHIHUAHUA
8155	VILLA AHUMADA	CHIHUAHUA
8156	VILLA CORONADO	CHIHUAHUA
8157	VILLA DE ALDAMA	CHIHUAHUA
8158	VILLALBA	CHIHUAHUA
8162	CAMARGO (DGE)	CHIHUAHUA
8165	CHIHUAHUA	CHIHUAHUA
8171	ESCALON (SMN)	CHIHUAHUA
8180	MACLOVIO HERRERA	CHIHUAHUA
8184	NUEVO CASAS GRANDES (SMN)	CHIHUAHUA
8185	PRESA CHIHUAHUA (DGE)	CHIHUAHUA
8202	PRESA FRANCISCO I. MADERO	CHIHUAHUA
8208	TEMOSACHI	CHIHUAHUA
8210	NUEVO CASAS GRANDES (DGE)	CHIHUAHUA
8213	JUAREZ (DGE)	CHIHUAHUA
8243	TEJOLOCACHI (DGE)	CHIHUAHUA
8254	OJINAGA (DGE)	CHIHUAHUA
8267	EL VERGEL (DGE)	CHIHUAHUA
8273	PARRAL A. EL HORMIGUERO	CHIHUAHUA
8298	DUBLAN	CHIHUAHUA
8303	C.E.M. CIUDAD DEPORTIVA	CHIHUAHUA
8311	COLINA	CHIHUAHUA
8322	EL VERGEL (CFE)	CHIHUAHUA
8326	PRESA ABRAHAM GONZALEZ	CHIHUAHUA
8332	LAS LAJAS	CHIHUAHUA