



Organización de las Naciones
Unidas para la Alimentación
y la Agricultura



Al servicio
de las personas
y las naciones



Programa de Integración de la agricultura en
los Planes nacionales de adaptación PNA-Ag

*Salvaguardar los medios de vida y promover la resiliencia
a través de los Planes nacionales de adaptación*



MINISTERIO DE GANADERÍA
AGRICULTURA Y PESCA
REPÚBLICA ORIENTAL DEL URUGUAY

Proyecciones climáticas mediante reducción estadística de escala para Uruguay

Proyecciones climáticas mediante reducción estadística de escala para Uruguay

Vanessa Bentancur y Mariana Molinari

Plan Nacional de Adaptación a la Variabilidad y el Cambio Climático para el Sector
Agropecuario (PNA-Agro)
Montevideo, 2019

La elaboración de esta publicación fue posible gracias al Programa Integración de la Agricultura en los Planes Nacionales de Adaptación (NAP-Ag), dirigido por la **Organización de las Naciones Unidas para la Alimentación y la Agricultura** (FAO) y el **Programa de las Naciones Unidas para el Desarrollo** (PNUD), con el apoyo de la Iniciativa Internacional para el Clima (IKI) del Ministerio Federal de Medio Ambiente, Conservación de la Naturaleza, Construcción y Seguridad Nuclear (BMUB) de Alemania. El proyecto de elaboración del Plan Nacional de Adaptación a la Variabilidad y el Cambio Climático para el Sector Agropecuario en Uruguay es implementado por la **Unidad Agropecuaria de Sostenibilidad y Cambio Climático de la Oficina de Programación y Política Agropecuaria** (OPYPA) del Ministerio de Ganadería, Agricultura y Pesca (MGAP). Los contenidos de esta publicación son responsabilidad de los autores y no reflejan las opiniones de la FAO, el PNUD o el BMUB.

Equipo del proyecto:

Ing. Agr. (M.Sc.) Walter Oyhançabal, Director de la Unidad Agropecuaria de Sostenibilidad y Cambio Climático

Ing. Agr. (M.Sc.) Cecilia Jones, Coordinadora Nacional del Plan Nacional de Adaptación a la Variabilidad y el Cambio Climático (PNA-Agro)

Ec. Carolina Balian, Especialista Técnico en el Plan Nacional de Adaptación a la Variabilidad y el Cambio Climático (PNA-Agro)

Mag. Leticia Ogues, Consultora en Comunicación para el Plan Nacional de Adaptación a la Variabilidad y el Cambio Climático (PNA-Agro)

Autores:

Vanessa Bentancur (contratada mediante acuerdo entre FAO y el Instituto SARAS)

Mariana Molinari (contratada mediante acuerdo entre FAO y el Instituto SARAS)

Edición:

Cecilia Jones

Corrección de estilo:

Leticia Ogues

Contenido

Resumen	1
1 Introducción.....	2
1.1 Cambio climático y modelado global	2
1.2 Reducción de escala.....	3
1.3 Proyecciones	4
2. Base de datos	6
3. Metodología.....	7
3.1 Procedimiento de reducción estadística de escala (<i>downscaling</i>).....	7
3.1.1 <i>Perfect prognosis</i>	7
3.1.2 Aplicación	9
3.2 Proyecciones	10
3.2.1 Temperatura media para el periodo.....	10
3.2.2 Serie proyectada	10
3.2.3 Indicador de olas de calor.....	11
3.2.4 Indicador de heladas.....	12
3.2.5 Evento extremo de precipitación.....	12
3.2.6 Indicador de déficit hídrico	12
4. Resultados.....	14
4.1 <i>Perfect prognosis</i>	14
4.1.1 Precipitación.....	14
4.1.2 Temperatura <i>máxima</i>	18
4.1.3 Temperatura mínima	19
4.2 Proyecciones: evolución de campos medios y de extremos	21
4.2.1 Evolución de campos medios.....	21
4.2.2 Evolución de extremos	27
5. Conclusiones.....	33
Bibliografía.....	34

Resumen

Este trabajo investiga cómo se relacionan los datos observados de precipitación, temperatura mínima y temperatura máxima de doce estaciones meteorológicas uruguayas en el periodo 1980-2010 con variables de circulación a gran escala salidas del reanálisis del modelo ERA-Interim-Dm para distintos dominios. De este análisis, realizado por medio de reducción estadística de escala, utilizando datos de observación revela que la precipitación está fuertemente relacionada con la humedad específica a 850 hPa y el viento horizontal a 700 hPa, mientras que las temperaturas máxima y mínima lo están con la humedad específica a 850 hPa y el geopotencial a 250 hPa. En el caso de la temperatura mínima existen otras variables que también logran tener alta correlación.

Las variables mejor relacionadas se utilizaron como predictores para analizar las variables e indicadores de olas de calor, eventos extremos e indicadores de déficit hídrico en distintos escenarios para los años 2010-2040 (corto plazo) y 2040-2070 (mediano plazo).

En las proyecciones se observó una evolución creciente en las tres variables estudiadas (precipitación, temperatura mínima y temperatura máxima) independientemente del escenario, periodo o temporada, aunque con diferencias en su magnitud. En los casos de las temperaturas máxima y mínima se observó un cambio mayor en la temporada fría, mientras que para la precipitación se proyecta un cambio mayor en la temporada cálida. Tanto en las temperaturas como en la precipitación se encontró una evolución positiva considerable.

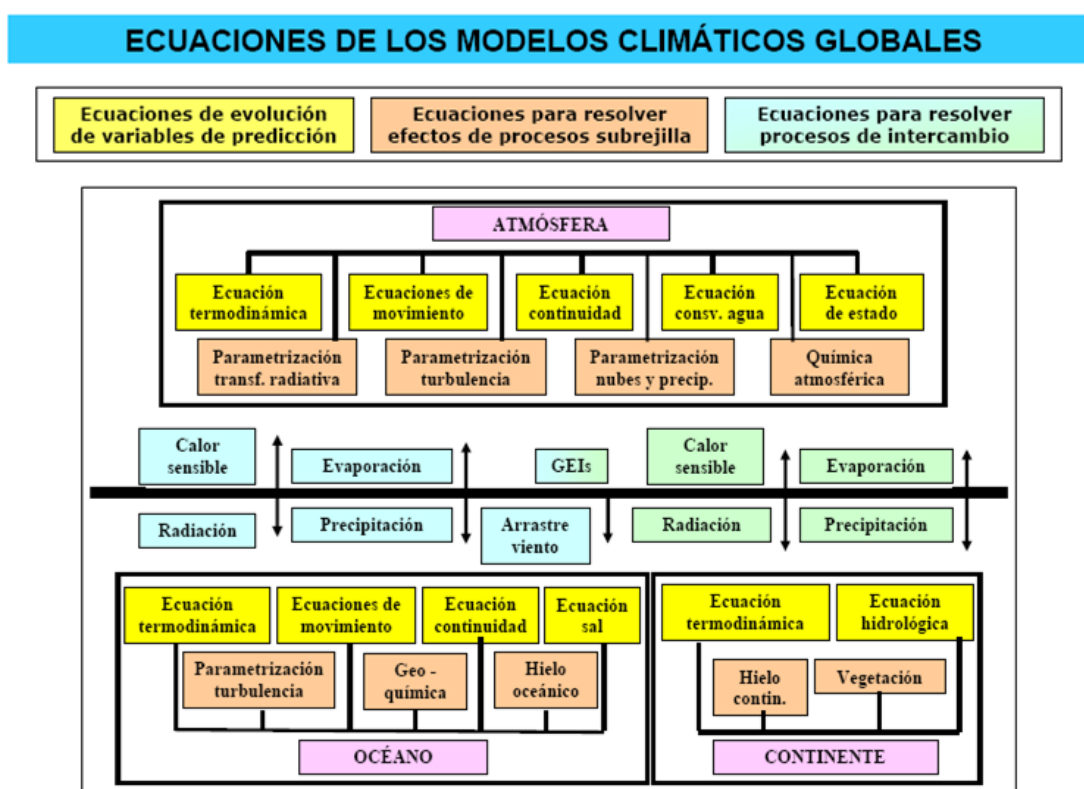
En el análisis de extremos, se encontró una evolución negativa del total de días con heladas. Con respecto a las olas de calor, se encontró una evolución positiva que señala que podría llegar a duplicarse la cantidad de eventos. En todos los modelos se encontró un aumento significativo positivo de temperatura media en todo el periodo para ambos escenarios. Con respecto al indicador de déficit hídrico, se observó una disminución en el periodo estudiado, más pronunciada para la temporada fría. A través del estudio de los eventos de precipitación de más de 20 mm no se pudo llegar a conclusiones significativas, aunque se observa un leve aumento en la región sur y más estabilidad en la región norte.

1 Introducción

1.1 Cambio climático y modelado global

Los modelos climáticos globales (GCM, por su sigla en inglés) contemplan múltiples factores, como se muestra en la Figura 1, incluyendo factores que no son solo atmosféricos. En particular, si observamos únicamente la atmósfera, esta se centra en cinco ecuaciones fundamentales (Figura 2): conservación de momento, conservación de masa, la ecuación constitutiva de gas ideal, conservación de energía y conservación del agua. Para poder trabajar con estas ecuaciones y con los distintos factores que integran los modelos, se necesita formular parametrizaciones/aproximaciones. La resolución de estas no es única, por lo que existen numerosos modelos climáticos desarrollados por distintas instituciones, que toman diferentes parametrizaciones, además de dar resultados en diferentes resoluciones espaciales.

Figura 1. Ecuaciones de GCM (*global climate models*)



Fuente: Portal de *Downscaling* de UNICAN.

Figura 2. Ecuaciones fundamentales de la atmósfera

$$\begin{aligned}\frac{dv}{dt} &= -\nabla\phi + F - 2\Omega \times v \\ \frac{\partial\rho}{\partial t} &= -\nabla \cdot (\rho v) \\ p\alpha &= RT \\ Q &= C_p \frac{dT}{dt} - \alpha \frac{dp}{dt} \\ \frac{\partial\rho q}{\partial t} &= -\nabla \cdot (\rho v q) + \rho(E - C)\end{aligned}$$


Nota: En donde: v = Velocidad, ϕ = Geopotencial, F = Fuerza de rozamiento, Ω = Velocidad angular de la Tierra, ρ = Densidad, α =volumen específico, R = Constante de gas ideal, T = Temperatura, Q = Flujo de Calor, C_p = Calor específico a presión constante, p = Presión atmosférica, q =relación de mezcla del vapor de agua, E = evaporación, C =condensación.

Fuente: Portal de *Downscaling* de UNICAN.

El beneficio del uso de uno u otro modelo no es evidente, ya que su habilidad no es igual ante todos los eventos. Pero es posible realizar una validación con observaciones para una región determinada. Por esto, es habitual que se estudie qué tan bien un modelo representa el pasado antes de considerar sus predicciones futuras. En este estudio se analizó la habilidad de los modelos para el periodo 1980-2010.

Para intentar saber cómo será el futuro se usan como base distintos escenarios de emisiones o de desarrollo que luego se introducen en los modelos. El Intergovernmental Panel on Climate Change (IPCC) elabora escenarios a futuro (RCP, por su sigla en inglés) considerando diversas variables, como la cantidad de contaminantes esperables en la atmósfera, el crecimiento demográfico, entre otras (Figura 3).

Figura 3. Escenarios 2013



Fuente: IPCC report graphics.

1.2 Reducción de escala

El objetivo de la reducción de escala es el aumento de la resolución espacial de los GCM para obtener resultados pertinentes a escalas locales.

Varios estudios han demostrado que el aumento de la resolución espacial permite además el aumento de definición y la visualización de nuevas estructuras, principalmente en zonas montañosas, donde los modelos globales tienden a generar mayores distorsiones. En este contexto, se han desarrollado varios métodos de reducción de escala para superar las limitaciones de los GCM en la simulación de las condiciones climáticas locales. Estos se pueden categorizar en dos tipos. Uno es el método de reducción de escala dinámico, en el que la simulación de alta resolución se obtiene utilizando un modelo climático regional que a su vez es impulsado por los resultados de una resolución GCM menor. Este método tiene el potencial de simular eventos extremos (Díez, *et al.*, 2005). Sin embargo, las simulaciones de alta resolución pueden ser computacionalmente costosas, y se requiere mucho espacio de almacenamiento para las salidas del modelo. El otro tipo es la reducción estadística de escala (Von Storch, Zorita y Cubasch, 1993), que busca encontrar una relación estable entre los resultados de los GCM a gran escala y variables del clima local. Esta relación se explota luego para predecir las características del clima regional futuro para esos GCM. La reducción de escala estadística es ampliamente utilizada debido a su menor requerimiento computacional.

El proceso de reducción estadística de escala comienza con la comparación de simulaciones de GCM, o reanálisis a gran escala, con el registro histórico a escala local. Esta etapa es conocida como *perfect prognosis*. Luego se utilizan los resultados como predictores, con los escenarios de los GCM, para obtener la proyección. Esta técnica supone que la relación predictor-predictando es estacionaria en un periodo de escala de varias décadas con escenarios climáticos distintos.

El grupo MetGroup Santander de la Universidad de Cantabria desarrolló una interfaz en línea que permite realizar la reducción estadística de escala en la que se trabaja cómodamente con las observaciones y modelos para obtener resultados en formatos simples. Esta interfaz es parte de la plataforma Sistema de Modelización de Impactos Agrícolas del Cambio Climático (MOSAICC, por su sigla en inglés). MOSAICC es un sistema de modelos y servicios diseñados para llevar a cabo una evaluación interdisciplinaria del impacto del cambio climático en la agricultura a través de simulaciones.

La inclusión de la base de datos uruguayo a este portal surge a través de la colaboración de distintas organizaciones, entre las que se encuentran: la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), el Instituto Sudamericano de Estudios sobre Resiliencia y Sostenibilidad (SARAS, por su sigla en inglés) y el Programa Naciones Unidas para el Desarrollo (PNUD). También se contó con el apoyo del Instituto Uruguayo de Meteorología (INUMET) y el Instituto Nacional de Investigación Agropecuaria (INIA), que proporcionaron la base de datos al portal.

1.3 Proyecciones

La predicción climática es compleja, sin embargo, entender que los sistemas de producción están expuestos a crecientes riesgos climáticos es clave para iniciar estrategias de adaptación que disminuyan la vulnerabilidad y aumenten la capacidad de recuperación de los agroecosistemas una vez que se produce un impacto.

En particular, los análisis de extremos son de gran importancia para la planificación del sector agropecuario debido al impacto de este tipo de eventos. Por ejemplo, los rumiantes se adaptan a las condiciones ambientales dentro de un cierto rango, sin embargo, hay ciertas ocasiones en las que sufren estrés térmico debido a las variaciones

de temperatura o por una combinación de factores negativos a los que son sometidos (Saravia, *et al.*, 2011).

Una ola de calor, en la que el ambiente meteorológico se encuentra fuera de la zona de confort térmico de la vaca, puede generar que esta reduzca su productividad a través de la disminución de su producción de leche (Hahn, 1995; 1999; Leva, *et al.*, 1996; Silanikove, 2000, citados en Saravia, *et al.*, 2011), cambios en la composición (Bianca, 1965; Sargent *et al.*, 1967; citados en Saravia, *et al.*, 2011), reducción en la eficiencia reproductiva del rodeo (Ingraham *et al.*, 1974; Ingraham, *et al.*, 1976; Thatcher y Staples, 1995; Flamenbaum, 1996; Jordan, *et al.*, 2003, citados en Saravia, *et al.*, 2011).

Cabe destacar que la mayoría de los eventos climáticos extremos no dependen de una sola variable, sino de varios parámetros. Las olas de calor dependen de la duración del periodo de temperatura elevada y de la humedad ambiente (Saravia, *et al.*, 2011). El déficit hídrico depende de la disponibilidad de agua en superficie, del agua precipitada, el tipo de suelo, entre otros. Para calcular si se va a producir una sequía se deben contemplar todos estos factores. Una posible técnica es la definida por Thornthwaite y Mather (1957) para definir balance hídrico meteorológico (BH) y luego calcular el índice de bienestar hídrico, que resulta de la relación entre la transpiración real y la demanda potencial diaria (ETR/ETP). El índice de bienestar hídrico permite caracterizar las condiciones hídricas en contextos agrícolas (Petrasovits, 1990, citado en Caorsi, *et al.*, 2014). Con respecto a las sequías, diversos estudios han mostrado que generan altos costos económicos inmediatos y afectan la base de recursos naturales del país (Caorsi, *et al.*, 2014).

En este trabajo se estudian indicadores ya que solo se contemplaron estudios de las variables precipitación, temperatura máxima y temperatura mínima como variables independientes, de modo que las proyecciones por medio de GCM deben tomarse como resultados orientativos.

2. Base de datos

Figura 4. Mapa de estaciones meteorológicas utilizadas



Fuente: Elaboración propia, 2018.

Para la selección de predictores se utilizaron 12 estaciones meteorológicas de INUMET y el INIA, para el periodo 1980-2010 (Tabla 1). Inicialmente se consideraron 15, pero luego de detectar inconsistencias causadas por diferentes factores, como la altitud, se descartaron 3. Además, en esta etapa se utilizaron datos provenientes del reanálisis ERA-Iterim-DM para el mismo periodo.

Para la etapa de las aplicaciones se utilizaron datos de los modelos que se mencionan en la Tabla 3, para el periodo 1970-2070.

Tabla 1. Estaciones meteorológicas utilizadas

Estación	Pertenencia	Longitud	Latitud
Artigas	INUMET	-56 ° 30'	-30 ° 23'
Carrasco	INUMET	-56 ° 00'	-34 ° 50'
Colonia	INUMET	-57 ° 16'	-34 ° 27'
Melo	INUMET	-54 ° 11'	-32 ° 22'
Mercedes	INUMET	-58 ° 04'	-33 ° 15'
Paso de los Toros	INUMET	-56 ° 31'	-32 ° 48'
Paysandú	INUMET	-58 ° 02'	-32 ° 10'
Rocha	INUMET	-54 ° 18'	-34 ° 29'
Salto	INUMET	-57 ° 58'	-31 ° 26'
La Estanzuela	INIA	-57 ° 41'	-34 ° 20'
Salto Grande	INIA	-57 ° 53'	-31 ° 16'
Tacuarembó	INIA	-55 ° 49'	-31 ° 42'

3. Metodología

3.1 Procedimiento de reducción estadística de escala (*downscaling*)

3.1.1 *Perfect prognosis*

La primera etapa del procedimiento es la de calibración y busca encontrar los predictores que se relacionen mejor con los predictandos para un dominio escogido de acuerdo con las necesidades. Se les llama predictores a las salidas de los reanálisis y predictandos a las observaciones. El reanálisis refiere a una nueva corrida del modelo de predicción que abarca todo el periodo, pero con la versión más actualizada de las condiciones iniciales y de borde, requisitos que deben cumplir las ecuaciones diferenciales del modelo. Los reanálisis son utilizados porque son los que más se aproximan a los datos reales integrados de una manera dinámicamente consistente.

Se realiza una validación mediante técnicas estadísticas generativas o no generativas, por ejemplo, regresión lineal o análogos entre predictores-predictando, y con base en los resultados se concluye si los predictores son los apropiados o no para pasar a la siguiente etapa. Una vez encontrados los predictores, se obtienen las relaciones estadísticas entre registros históricos y reanálisis de campos de gran escala. Es importante destacar que se debe realizar un proceso de pruebas con diferentes predictores para encontrar el más adecuado en cada caso y que los predictores deben ser seleccionados con conocimiento de las relaciones físicas entre ellos y los predictandos.

Paso 1: Selección del predictor

La reducción estadística de escala utiliza los datos de reanálisis para generar relaciones robustas con las observaciones. Para encontrar estas relaciones se utilizan las variables predictoras. Esta es una de las etapas fundamentales de la técnica de *downscaling* debido a que los resultados de las proyecciones dependen fuertemente de los predictores. Un factor importante para la etapa de aplicación es la elección de variables cuya evolución pueda ser bien simulada por los GCM. Por tanto, es recomendable priorizar aquellas que son representativas del movimiento de gran escala.

En la fase de *perfect prognosis* se utilizaron varios índices, obtenidos mediante el portal MOSAICC, que reflejan una relación comparativa entre las predicciones a escala local y las observaciones históricas. En el presente informe se describen cuatro de ellos: la correlación de Pearson para las temperaturas, la correlación de Spearman para la precipitación, el sesgo (*bias*), el cociente de varianzas (RV) y la distancia entre las funciones de densidad de probabilidad (PDF-score).

La correlación de Pearson se define como la fortaleza de la relación lineal entre las predicciones y las observaciones. Su rango es de -1 a 1, el valor óptimo es 1 y se calcula mediante la siguiente ecuación:

$$\rho = \frac{\text{cov}(o, f)}{\sigma_o \sigma_f}$$

en donde o representa los datos observados, f los pronosticados, cov es la covarianza entre o y f y σ son desviaciones estándar de las respectivas variables.

La correlación de Spearman se define a partir de la correlación de Pearson, pero con base en el ordinal de la variable, con lo cual captura también las relaciones no lineales. Al igual que en la correlación de Pearson, su rango es de -1 a 1 y el valor óptimo es 1. Se puede calcular mediante la siguiente ecuación:

$$\rho_s = \frac{6 \sum_{i=1}^n (o_i - f_i)^2}{n(n^2 - 1)}$$

en donde n es el número de pares de datos.

El sesgo se define como el promedio del error de las predicciones. Su rango es de $-\infty$ a $+\infty$ y el valor óptimo es 0. Se puede calcular mediante la siguiente ecuación:

$$\text{Sesgo} = \frac{1}{n} \sum_{i=1}^n (o_i - f_i)$$

El RV o cociente de varianzas se define como el cociente entre las varianzas de las observaciones y las predicciones. Su rango va de 0 a $+\infty$ y su valor óptimo es 1. Se calcula mediante la siguiente ecuación:

$$\text{RV} = \frac{\sigma_f^2}{\sigma_o^2}$$

El PDF-score se define como la superposición entre la función empírica de la densidad de probabilidad de las observaciones y predicciones. Su rango va de 0 a 1 y el valor óptimo es 1. Se puede calcular mediante la siguiente ecuación (INUMET):

$$\text{PDF} = \sum_{i=1}^{200} \text{PDF}_{fi} - \text{PDF}_{oi}$$

en donde el número 200 indica las clases para el rango de los datos.

La variable con el coeficiente de correlación más alto con el predictando puede ser una buena opción para un predictor (Kang, *et al.*, 2007). Las variables de uso general a gran escala para predecir la precipitación incluyen la altura geopotencial (Von Storch y Zwiers, 1999), presión a nivel de superficie (SLP) (Wetterhall, Halldin y Xu, 2005), viento geostrófico (Wilby, *et al.*, 1998) y la velocidad del viento (Murphy, 1999).

Los predictores considerados en este estudio fueron: geopotencial (ϕ), viento horizontal (u, v), humedad específica a distintos niveles.

Si bien estudios como los realizados por Feddersen y Andersen (2005) o Chu, *et al.* (2008) utilizan variables como la temperatura a 2 metros y la presión a nivel de superficie (SLP), los modelos climáticos no son buenos pronosticando variables en superficie por lo que estas no son aconsejables como predictores. Otros predictores disponibles, como temperatura promedio, temperatura máxima y mínima en superficie, precipitación y humedad relativa, no fueron utilizados por la misma razón.

Estas definiciones de estadísticos fueron extraídas del manual del portal de *downscaling*.

Paso 2: Selección del predictando

Se realizaron los estudios para las variables precipitación, temperatura máxima y temperatura mínima debido a que son variables afectadas por el cambio climático y de gran importancia por su impacto en la producción agropecuaria.

Paso 3: Selección del dominio

Dada la resolución de los distintos GCM (Tabla 2) es aconsejable no utilizar resoluciones de menos de dos grados.

Tabla 2. Resoluciones de los modelos GCM

Modelo	Resolución horizontal	Referencia
CanESM2	2,8x2,8°	Chylex, <i>et al.</i> (2011)
CNRM-CM5	1,4x,4°	Valdoire, <i>et al.</i> (2011)
NorESM1-M	1,5x1,9°	Kirkevåg, <i>et al.</i> (2008)
IPSL-CM5-MR	1,5x1,27°	Dufresne, <i>et al.</i> (2005)
MIROC-ESM	2,8x2,8°	Watanabe, <i>et al.</i> (2011)

Fuente: Portal de *Downscaling* de UNICAN.

La dependencia de los resultados de la reducción de escala con el dominio es muy grande, por ejemplo, puede ocurrir que con un dominio se encuentren correlaciones de 0,50 para un predictor determinado, mientras que para otro dominio presenten correlaciones de 0,80.

Para la elección del dominio se debe evaluar que sea suficientemente extenso para ver procesos en altura. Por otro lado, debe permitir modelar fenómenos que tienen una influencia diaria a escala local, por lo que se requiere que no sea demasiado grande. El lugar donde el coeficiente de correlación entre un predictando y un predictor es cero puede considerarse como el límite de adecuación de un dominio (Benestad, 2004). Otra base para la selección de un dominio es que debe ser lo suficientemente grande para resolver el patrón relevante a gran escala y abarcar también observaciones locales (Feddersen y Andersen, 2005). Al analizar los distintos dominios no se encontró ninguno en el que la correlación fuera 0, razón por la cual se optó por realizar la selección según lo planteado por Feddersen y Andersen (2005).

Como se verá más adelante, para el caso de Uruguay es oportuno considerar la región del sudoeste, mientras que es perjudicial considerar la zona atlántica. Esto es coherente con el hecho observado de que los sistemas sinópticos se trasladan en dirección este en latitudes medias como la de Uruguay.

Paso 4: Método de reducción de escala

Como ya fue mencionado, existen distintos métodos para realizar la reducción de escala. Para este trabajo se hicieron estudios mediante el método de análogos seleccionando entre 1-10 y por método de componentes principales. En este informe solo se muestran trabajos realizados mediante análogos, ya que presentan mejores resultados en la validación.

3.1.2 Aplicación

La aplicación consiste en tomar las relaciones generadas mediante el ajuste en la primera etapa entre los registros históricos y los reanálisis, seleccionar un escenario de IPCC y aplicar dichas relaciones a las simulaciones de los GCM. De esta forma, a partir de los GCM y las relaciones mencionadas se obtienen las proyecciones para el periodo

deseado. Este método, como se mencionó antes, asume que la relación entre predictando y predictor se mantiene a futuro, es estacionaria, y que los GCM son capaces de generar escenarios de las variables de gran escala usadas como predictores.

Para cada GCM de los que se muestran en la Tabla 3 se realizaron simulaciones para los periodos 1970-2000, con el fin de utilizarlos como base de datos de climatología consistente de cada modelo, y se generaron proyecciones en el periodo 2010-2070 para cada modelo.

Tabla 3. Modelos climáticos globales utilizados

Modelo	Procedencia
CMIP5-CANESM2	Canadian Centre for Climate Modelling and Analysis
CMIP5-CNRM-CM5	Météo-France and CERFACS
CMIP5-GFDL-ESM2M	NOAA
CMIP5-MPI-ESM-MR	The Max Planck Institute

Fuente: Elaboración propia, 2018.

En la sección 4 de este trabajo se explica con más detalles qué evaluar en cada paso.

3.2 Proyecciones

En el análisis de las proyecciones se evaluaron los escenarios RCP 4.5 y 8.5. Para definir los indicadores de extremos utilizados se usaron los índices que aparecen en IPCC-AR5, además de los utilizados por Frich, *et al.* (2002), quienes realizaron un análisis global en el que destacaban que América del Sur era una de las regiones del mundo para las que hasta ese momento existía muy poca información, y los utilizados por Vincent, *et al.* (2005) y Haylock, *et al.* (2006), quienes realizaron estudios en los que se incluía esta región. También se utilizaron los trabajos de Renom (2009) y Saravia, *et al.* (2011).

3.2.1 Temperatura media para el periodo

Se realizó un estudio de la temperatura media para toda la serie y se la definió como:

$$\bar{T} = \frac{T_{\max} + T_{\min}}{2}$$

3.2.2 Serie proyectada

Se realizó el estudio de las *series proyectadas* para el promedio de las doce estaciones meteorológicas de referencia. Para cada una de las variables se realizó un estudio de evolución de cada modelo, separándolas por temporada cálida (que abarca los meses entre octubre y marzo) y temporada fría (que incluye los meses entre abril y setiembre). De aquí en más, cada vez que se hable de temporadas en este documento se usarán estas definiciones.

Al analizar las proyecciones para cada modelo, para el promedio mensual en el caso de la temperatura y para el acumulado mensual en el caso de la precipitación, se resta la climatología histórica de la siguiente manera:

$$\Delta\bar{T} = \bar{T}_{\text{simulada}} - \bar{T}_{\text{historica}}$$

En el caso de la precipitación, los resultados se expresaron en porcentaje para poder visualizarlos mejor. Además estudiar la serie de precipitación en acumulados mensuales, se evaluaron en particular los periodos 2010-2040 y 2040-2070.

$$\Delta \overline{pp} = \frac{\overline{pp}_{simulada} - \overline{pp}_{historica}}{\overline{pp}_{historica}} * 100$$

Por otra parte, para analizar la existencia de tendencia en la serie se realizó el test Mann-Kendall (Wilks, 2011). Este es un test no paramétrico y, como tal, no es dependiente de la magnitud de los datos ni de las hipótesis de distribución (no depende de que los datos tengan una distribución específica).

El test de Mann-Kendall evalúa si un conjunto está ordenado y si el ordinal es el tiempo, lo que equivale a la existencia de una tendencia creciente o decreciente en un nivel predeterminado de significancia.

Cada par de valores observados y_i, y_j ($i > j$) de la variable aleatoria es inspeccionado para encontrar cuando $y_i > y_j$ o $y_i < y_j$.

Si el número de pares positivos es P y el número del tipo de pares negativos es M , entonces el estadístico S se define como $S = P - M$. Para $n > 10$, se puede definir una estadística Z que sigue la distribución estándar normal, donde:

$$Z = \begin{cases} (S - 1)/\sigma_s & \text{if } S > 0 \\ 0 & \text{if } S = 0 \\ (S + 1)/\sigma_s & \text{if } S < 0 \end{cases}$$

$$\sigma_s = \sqrt{\frac{n(n-1)(2n+5)}{18}}$$

El test tiene hipótesis nula H_0 =no hay tendencia, y la alternativa es H_1 =existe tendencia a cierto nivel de significancia a elegir. Si el test da como resultado 1, significa que se puede rechazar H_0 .

La función utilizada para realizar este test permite obtener el *p-valor*, es decir, el punto en el que H pasa de dar 0 a valer 1, que es el valor que permite rechazar H_0 y decir que es posible la existencia de tendencia, por ejemplo, un p-valor de 0,05 indica que se puede aceptar la hipótesis de tendencia al 95 %.

3.2.3 Indicador de olas de calor

Como indicador de las olas de calor, se contabilizan situaciones en las que al menos en tres días consecutivos la temperatura máxima del día supera la media para ese día, adicionando tres veces la desviación estándar de la temperatura máxima histórica para dicha fecha, es decir:

$$\overline{T}_{\max 3 \text{ días}} > \overline{T}_{\text{media histórica}} + 3\sigma$$

En este análisis se tomó para cada periodo, modelo y escenario la cantidad máxima de eventos de olas de calor entre todas las estaciones.

3.2.4 Indicador de heladas


Para realizar el análisis de heladas se contó la cantidad de días en cada década en los que la temperatura mínima fue menor a 0 °C ($T_{\min} \leq 0$) y se incluyeron los años utilizados como climatología. Luego se realizó un ajuste polinomial de grado 4 para una mejor visualización.

Dada la distancia entre los puntos de interés, para este estudio se consideró independencia entre ellos. Por tal motivo, se contaron sin tener en cuenta en qué estación sucedieron.

3.2.5 Evento extremo de precipitación

Siguiendo las referencias citadas antes, se definieron como eventos extremos puntuales los días en los que la precipitación superó los 20 mm.

Figura 5. Mapa de precipitación media anual observada (1961-1990)



Fuente: INUMET.

Este análisis se hizo considerando dos regiones, como lo muestra la Figura 5, usando como delimitador la franja de precipitaciones de 1.200-1.300 mm. También se dividió en temporada cálida y fría. El análisis de este índice se puede utilizar como indicador de exceso hídrico.

3.2.6 Indicador de déficit hídrico

El valor promedio de la precipitación mensual acumulada resulta ser un indicador pobre de déficit hídrico, dado que rara vez sigue una distribución normal y su uso indebido puede conducir a conclusiones erróneas.

Por ello, basándonos en el método utilizado por INUMET, separamos la precipitación mensual acumulada en quintiles:

- 1 Muy Seco
- 2 Seco
- 3 Normal
- 4 Lluvioso
- 5 Muy Lluvioso

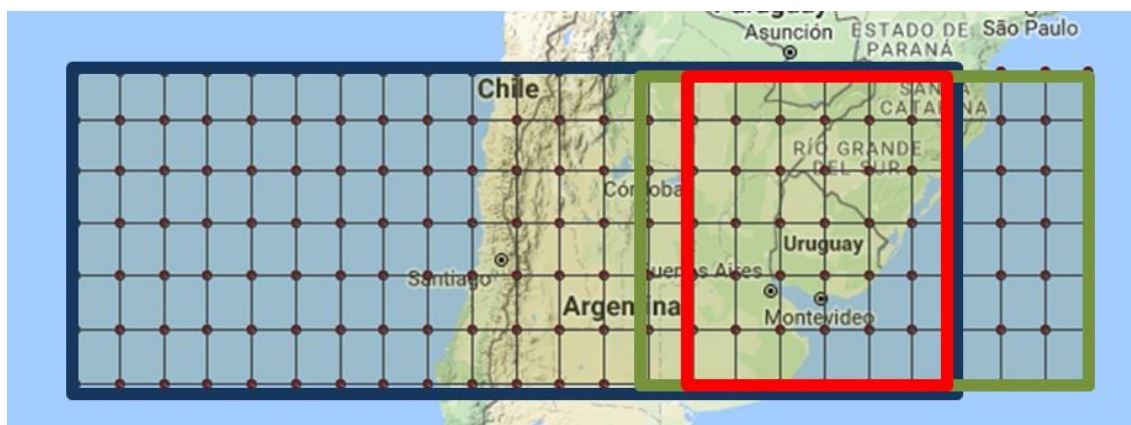
Para indicar la posible presencia de déficit hídrico sobre los acumulados mensuales, contemplamos solo los valores dentro de los quintiles 1-2. Para ello, se ordenó la climatología y se separaron los quintiles. Luego se comparó la serie con los quintiles para identificar su pertenencia.

4. Resultados

4.1 *Perfect prognosis*

Se probaron treinta combinaciones de predictores para cada una de las variables a estudiar, lo que incluyó el estudio de grupos de predictores en distintas alturas y tres dominios, que se pueden ver en la Figura 6.

Figura 6. Dominios estudiados



Nota: Dominio 1 (verde): Longitud: -64° a -44° W Latitud: -38° a -26° S; Dominio 2 (rojo): Longitud: -62° a -50° W Latitud: -38° a -26° S; Dominio 3 (azul): Longitud: -90° a -50° W Latitud: -38° a -26° S.

Fuente: Elaboración propia, 2018.

El dominio 1 se seleccionó pensando en la influencia que puede tener el Atlántico sobre el clima de la región, considerando el flujo a niveles bajos y desestimando la circulación en bajos niveles sobre el otro lado de Los Andes, siempre buscando la mayor eficiencia de los modelos de gran escala.

En el dominio 2, en cambio, se trató de incorporar las influencias más cercanas a la región.

Finalmente, el dominio 3 busca mostrar la influencia de las variables en altura al oeste de la zona de interés, desde donde provienen los sistemas sinópticos.

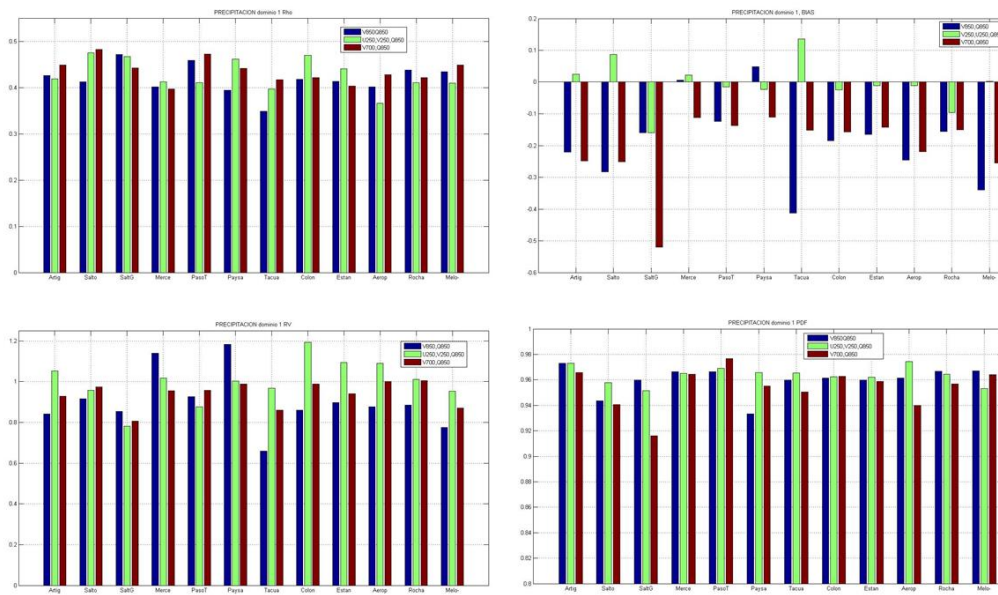
Al analizar los estadísticos de cada dominio, se llegó a la conclusión de que el que mejor ajusta es el dominio 2, es decir, el que solo incluye una zona muy similar al territorio uruguayo.

4.1.1 Precipitación

Para realizar los estudios de la precipitación se utilizaron datos acumulados de diez días, porque los datos diarios tienen una variabilidad muy alta que imposibilitaría la visualización de patrones, mientras que a través de un acumulado de diez días se puede observar una mayor homogeneidad.

Al analizar los tres dominios, se observa que las correlaciones varían entre 0,26-0,63, según la agrupación de predictores y la altura en la que se los considere. Se encuentra que el nivel geopotencial que mejores resultados produce es el de 700 hPa. En la Figura 7 y la Figura 8 se muestran resultados para los dominios 1 y 2.

Figura 7. Correlación sesgo-RV-PDF para precipitación en el dominio 1

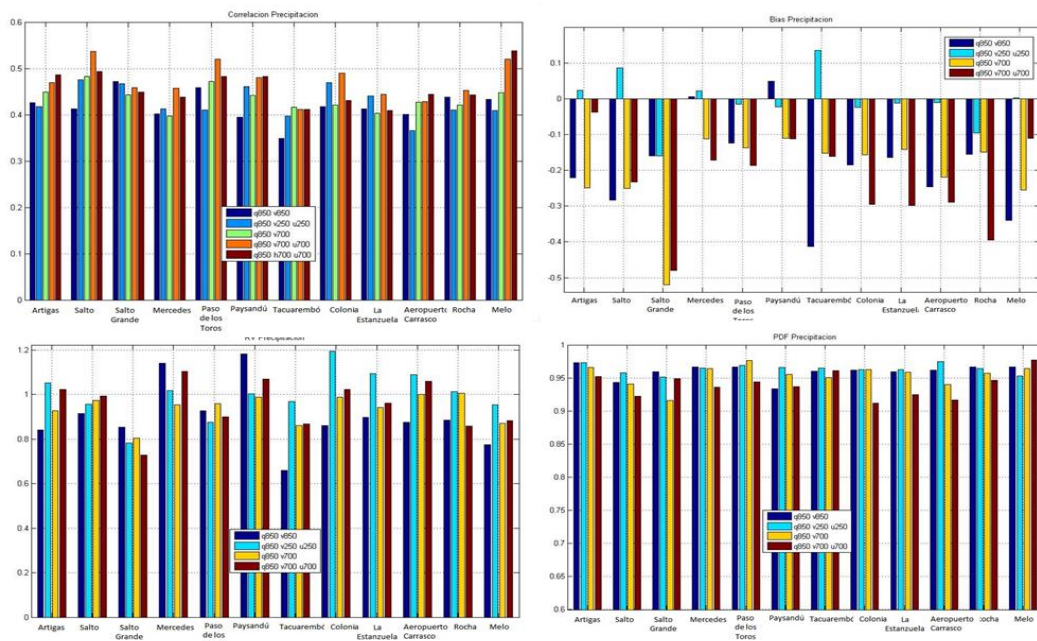


Nota: En azul aparecen los coeficientes para los predictores viento meridional y humedad específica, ambos a 850 hPa; en verde, viento meridional, viento zonal a 250 hPa y humedad específica a 850 hPa; en rojo, viento meridional a 700 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

Para el dominio 1 se encuentra una correlación máxima entre todos los predictores de 0,48, mientras que en el dominio 2 hay un máximo en correlación de 0,63 y en el dominio 3 se llega a 0,49. Por lo tanto, se selecciona el dominio 2, teniendo en cuenta también los valores del sesgo, RV y PDF. En la Figura 7 se muestran algunos de los resultados obtenidos para dicho dominio.

Figura 8. Correlación sesgo-RV-PDF para precipitación en el dominio 2



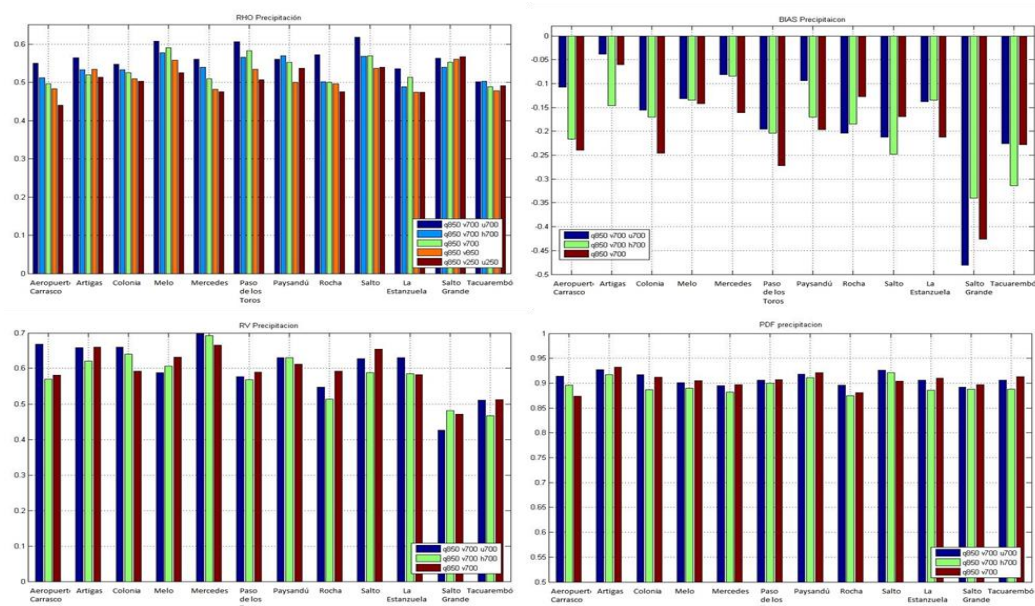
Nota: Gráfico 1: en azul aparecen los coeficientes para los predictores viento meridional a 850 hPa y humedad específica a 850 hPa; en turquesa, viento meridional, viento zonal a 250 hPa y humedad específica a 850 hPa; en verde, viento meridional a 700 hPa y humedad específica a 850 hPa; en naranja, viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa; en rojo, viento meridional, geopotencial a 700 hPa y humedad específica a 850 hPa. En los Gráficos 2-4: en azul aparecen los coeficientes para los predictores viento meridional y humedad específica, ambos a 850 hPa; en turquesa, viento meridional, viento zonal a 250 hPa y humedad específica a 850 hPa; en amarillo, viento meridional a 700 hPa y humedad específica a 850 hPa; en rojo, viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

Para el dominio 2 podemos decir que tanto el grupo de dos variables (viento meridional a 700 hPa y humedad específica a 850 hPa) como los grupos de tres variables (se agregan al grupo anterior la velocidad zonal a 700 hPa y geopotencial a 700 hPa) tienen resultados similares. En cuanto a la correlación, se destaca el grupo que contiene velocidad zonal a 700 hPa, cuyos resultados ofrecen valores mayores. Luego de considerar las ventajas y desventajas de estos predictores, se decidió seleccionar velocidad zonal y meridional en 700 hPa y humedad específica en 850 hPa para realizar las proyecciones. La selección de variables a niveles bajos es coherente con la elección de un dominio relativamente chico.

En la Figura 8, la Figura 9 y la Figura 10 se muestran algunos de los resultados obtenidos para el dominio 2 para 1, 3 y 5 análogos.


Figura 9. Correlación sesgo-RV-PDF para precipitación en el dominio 2 con 3 análogos



Nota: Gráfico 1: en azul aparecen los coeficientes para los predictores viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa; en turquesa, viento meridional, geopotencial a 700 hPa y humedad específica a 850 hPa; en verde, viento meridional a 700 hPa y humedad específica a 850 hPa; en naranja, viento meridional a 850 hPa y humedad específica a 850 hPa; en rojo, viento meridional, viento zonal a 250 hPa y humedad específica a 850 hPa. En los Gráficos 2-4: en azul aparecen los coeficientes para los predictores viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa; en verde, viento meridional, geopotencial a 700 hPa y humedad específica a 850 hPa; en rojo, viento meridional a 700 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

Figura 10. Correlación sesgo-RV-PDF para precipitación en el dominio 2 con 5 análogos



Nota: Gráfico 1: en azul aparecen los coeficientes para los predictores viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa, en turquesa viento meridional, geopotencial a 700 hPa y humedad específica a 850 hPa; en verde, viento meridional a 700 hPa y humedad específica a 850 hPa; en


naranja, viento meridional a 850 hPa y humedad específica a 850 hPa; en rojo, viento meridional, viento zonal a 250 hPa y humedad específica a 850 hPa. En los Gráficos 2-4: en azul aparecen los coeficientes para los predictores viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa; en verde, viento meridional, geopotencial a 700 hPa y humedad específica a 850 hPa; en rojo, viento meridional a 700 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

En la Figura 11 se muestran los resultados para velocidad zonal y meridional en 700 hPa y humedad específica en 850 hPa para el dominio 2, y se incluye la prueba del método de análogos con distintas cantidades: 1, 3 y 5. En los tres casos se encuentran ventajas y desventajas. Cuanto más alto es el número de análogos, mayor es la correlación, pero, como contrapartida, desmejoran los valores de sesgo, RV y PDF.

Si bien el incremento en el número de análogos mejora la correlación, se pierde varianza en los resultados (el efecto es más claro en la precipitación, que naturalmente tiene una mayor variabilidad que la temperatura). La pérdida de varianza no resulta deseable porque los sistemas agropecuarios son muy sensibles a la variabilidad de lluvia y no solo a las medias, por lo cual es preferible usar un análogo.

Figura 11. Grupo de predictores elegido (viento meridional, viento zonal a 700 hPa y humedad específica a 850 hPa) para precipitación con 1, 3 y 5 análogos




Fuente: Elaboración propia, 2018.

4.1.2 Temperatura máxima

Del mismo modo que para la variable precipitación, se observa que el dominio 2 es el que mejor ajusta al análisis de la temperatura máxima, por este motivo solo se muestran sus resultados.

Figura 12. Correlación sesgo-RV-PDF para temperatura máxima



Nota: En azul aparecen los coeficientes para los predictores viento zonal a 500 hPa, geopotencial a 250 hPa y humedad específica a 850 hPa; en verde, viento meridional, viento zonal a 850 hPa y humedad específica a 850 hPa; en rojo, geopotencial 250 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

A partir de las estadísticas realizadas, se encontró una fuerte dependencia entre la humedad específica y la temperatura (Figura 12). También se observó que la velocidad meridional influye en la misma medida que el geopotencial y que el viento zonal no contribuye.


Se seleccionaron como predictores la humedad específica a 850 hPa y el geopotencial en 250 hPa, y se utilizaron cinco análogos, ya que la correlación mejora considerablemente respecto a los análogos 1 y 3, mientras que los otros índices no empeoran de forma significativa. Además, se observó una dependencia casi imperceptible con los distintos niveles de geopotencial (Figura 12).

4.1.3 Temperatura mínima

Dado que en el caso de este predictando los resultados no variaban demasiado con el dominio, se optó por el dominio 2, elegido para los casos anteriores.

Del análisis realizado para esta variable, se observa en primer lugar que los resultados son mejores que para las otras variables estudiadas y que permite obtener muchos grupos de predictores óptimos. Independientemente del dominio y con la humedad específica a 850 hPa como único predictor, resultó con altos valores de correlación. Sin embargo, se seleccionó, igual que para la temperatura máxima, el grupo de humedad específica a 850 hPa y el geopotencial a 250 hPa, ya que fue en el que se obtuvieron las mayores correlaciones.

Figura 13. Correlación sesgo-RV-PDF para temperatura mínima con 1 análogo




Nota: En azul aparecen los coeficientes para los predictores viento zonal a 500 hPa, geopotencial a 250 hPa y humedad específica a 850 hPa; en verde, viento meridional, viento zonal a 850 hPa y humedad específica a 850 hPa; en rojo, geopotencial 250 hPa y humedad específica a 850 hPa.

Fuente: Elaboración propia, 2018.

Con respecto a las diferentes cantidades de análogos, se llegó a la misma conclusión que en el caso de la temperatura máxima: al utilizar cinco análogos las correlaciones aumentan considerablemente, pero los valores de sesgo, RV y PDF no cambian tanto. La Figura 13 y la Figura 14 muestran los resultados para las mismas variables con uno y cinco análogos.

Figura 14. Correlación sesgo-RV-PDF para temperatura mínima con 5 análogos y correlación sesgo-RV-PDF para temperatura mínima con 1 análogo



Nota: En azul aparecen los coeficientes para los predictores viento zonal a 500 hPa, geopotencial a 250 hPa y humedad específica a 850 hPa; en verde, geopotencial a 250 hPa y humedad específica a 850 hPa; en rojo, humedad específica a 850 hPa.

4.2 Proyecciones: evolución de campos medios y de extremos

En esta sección se muestran los resultados obtenidos para las proyecciones, la evolución de las variables y los extremos.

Como se mencionó antes, se obtuvieron proyecciones de temperaturas máxima y mínima mediante el método de cinco análogos y para la precipitación por el método de un análogo.

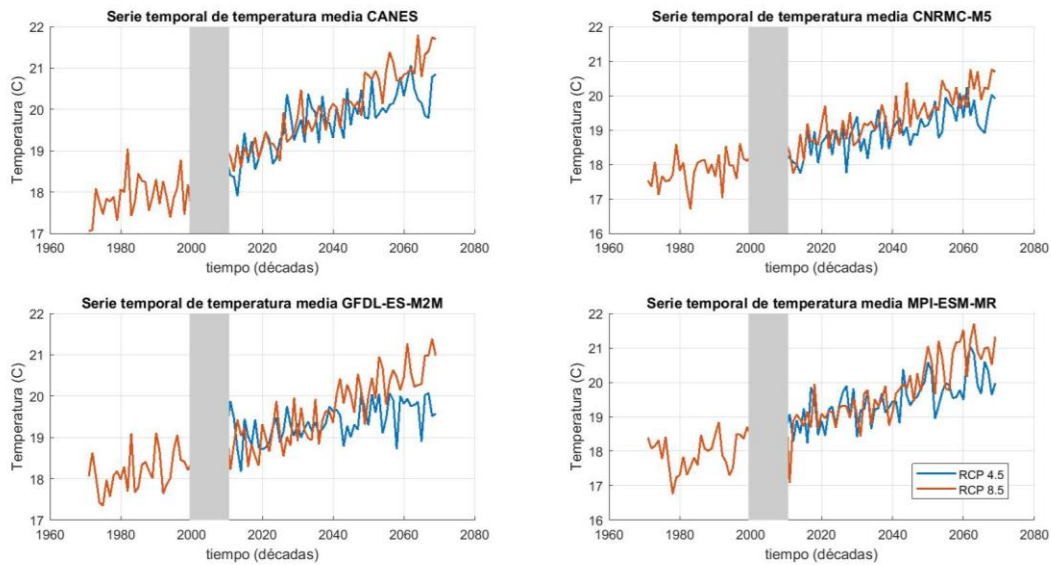
Se ajustaron las simulaciones de temperatura máxima y mínima mediante los predictores humedad específica a 850 hPa y geopotencial en 250 hPa y las de precipitación mediante los predictores velocidad zonal y meridional a 700 hPa y humedad específica a 850 hPa.

4.2.1 Evolución de campos medios

4.2.1.1 Temperatura media para el periodo

La Figura 15 muestra la temperatura media para los cuatro modelos estudiados y los dos RCP considerados.

Figura 15. Serie temporal de temperatura media para los distintos escenarios



Nota: En celeste aparece el escenario RCP 4.5 y en naranja el RCP 8.5; la franja gris representa el salto entre el final de las simulaciones históricas (año 2000) y el comienzo de las proyecciones con RCP (año 2010).

Fuente: Elaboración propia, 2018.

Para todos los modelos y escenarios se proyecta un aumento en la temperatura media en el periodo considerado.

Por otra parte, se observa que el modelo GFDL-ES-M2M proyecta entre los años 2010 y 2030 un cambio mayor para el escenario RCP 4.5, que se invierte a partir del 2030. Para los otros tres modelos, desde 2010 en adelante se visualiza un aumento mayor en el escenario RCP 8.5.

Se puede notar que a medida que pasan los años crecen las diferencias entre los escenarios con respecto al cambio de la temperatura. Si se aplica un ajuste lineal a los datos, la diferencia entre los RCP para el final del periodo tiene una amplitud de aproximadamente 1 °C.

Si se observa la media en todo el periodo para el caso del RCP 4.5, la amplitud total depende del modelo: mientras que el CANESM2 presenta casi 3 °C, los demás se ubican entre 1,5 °C y 2 °C. Para el RCP 8.5, en casi todos los casos hay 2,5 °C de amplitud, salvo en CANESM2, que tiene aproximadamente 3 °C.

Para verificar la posible tendencia observada en los resultados anteriores, se les aplicó el test de Mann-Kendall por modelo y escenario. Esto permitió comprobar una tendencia positiva para todos los modelos al 95 %, con p-valores iguales a 0.

Finalmente, si comparamos estos resultados con lo estudiado por Bidegain (2016), tanto las diferencias entre los escenarios como la proyección coinciden en rasgos generales.

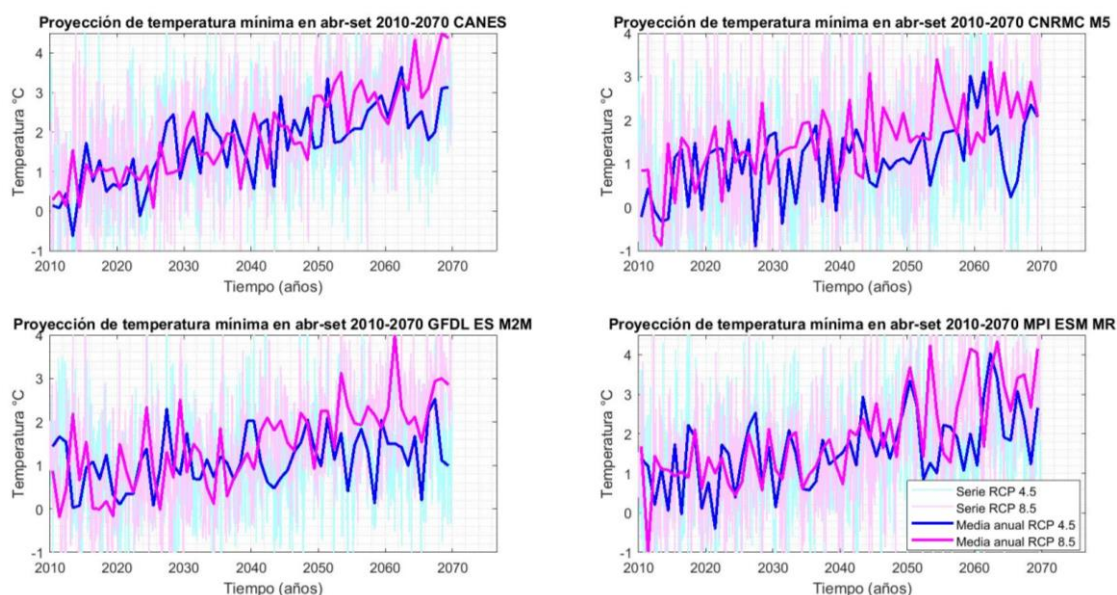
4.2.1.2 Proyección de temperatura mínima

Como se aprecia en la Figura 16 y la Figura 17, para el periodo 2010-2070 se ve en la temperatura mínima una evolución positiva mayor en la temporada fría, en la mayoría de los modelos. Además, se observa una evolución similar en los dos escenarios para el

periodo 2010-2040, independientemente de la temporada, mientras que en la el periodo 2040-2070 se comienza a notar diferencias entre ellas.

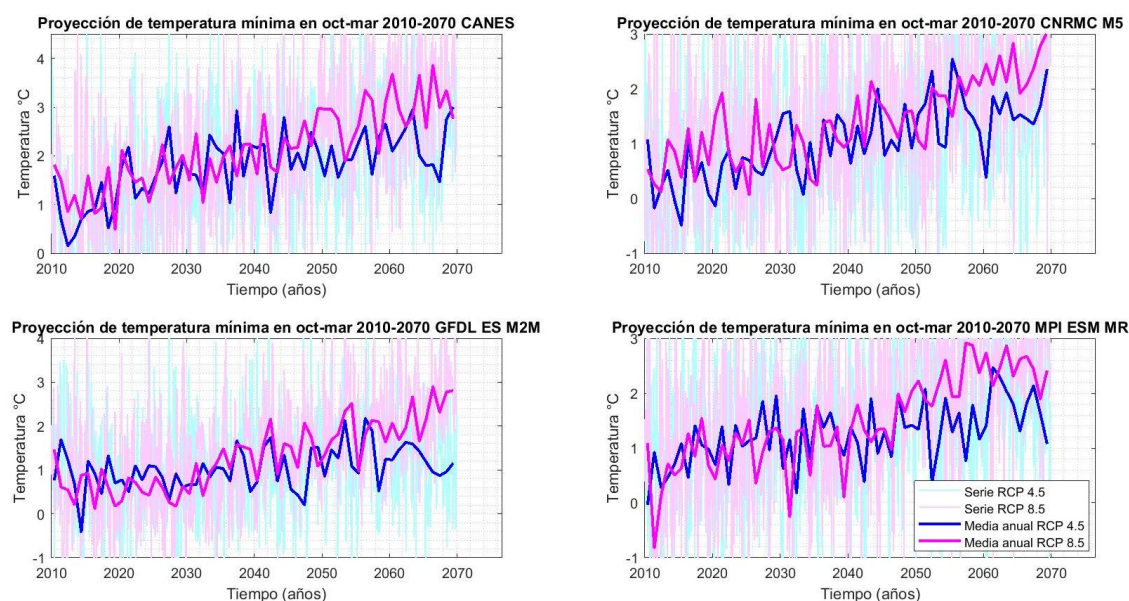
Al considerar las dos temporadas juntas en el periodo 2010-2040, se aprecia una evolución promedio correspondiente a un aumento de entre 0,6 °C y 1,3 °C para el RCP 4.5 y de entre 0,8 °C y 1,3 °C para el RCP 8.5. En cambio, para el periodo 2040-2070 se espera un incremento de entre 1,3 °C y 2,2 °C para el RCP 4.5 y de entre 2 °C y 2,7 °C para el RCP 8.5, lo que indica una diferencia importante entre los distintos escenarios para este periodo.

Figura 16. Evolución de la temperatura mínima en temporada fría



Fuente: Elaboración propia, 2018.

Figura 17. Evolución de la temperatura mínima en temporada cálida




Fuente: Elaboración propia, 2018.

4.2.1.3 Proyección de temperatura máxima

Como lo muestran la Figura 18 y la Figura 19, en la *temperatura máxima* se observa que el modelo CANESM2 proyecta mayores cambios en casi todos los casos.

Figura 18. Evolución de la temperatura máxima en temporada fría

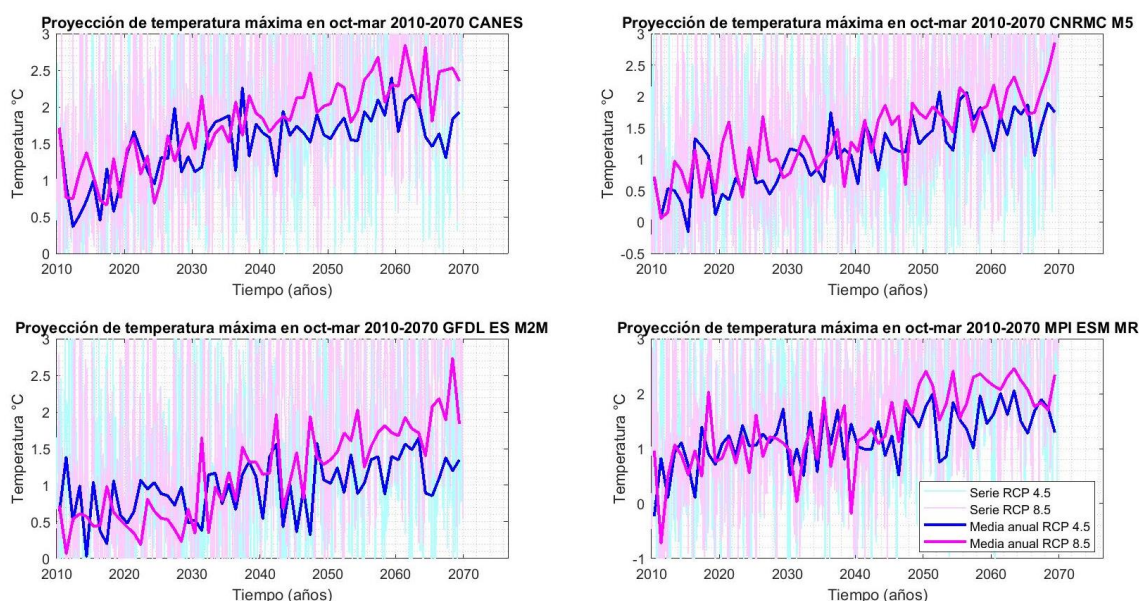


Fuente: Elaboración propia, 2018.

Tanto para el periodo 2010-2040 como para el periodo 2040-2070, se aprecia una mayor evolución en la temporada fría, lo que implica un aumento mayor de temperatura con respecto a la climatología en otoño-invierno que en primavera-verano.

Considerando ambas temporadas juntas, en el periodo 2010-2040 y el RCP 4.5 se observa una proyección de aumento de temperatura con valores comprendidos entre 0,9 °C y 1,5 °C, bastante similares a los del RCP 8.5, que se ubican entre 1 °C y 1,5 °C. En cambio, en el periodo 2040-2070 se observa una diferencia importante entre los modelos: los valores pasan a ser de entre 1,6 °C y 2,4 °C para el RCP 4.5 y de entre 2,2 °C y 3 °C para el RCP 8.5.

Figura 19. Evolución de la temperatura máxima en temporada cálida




Fuente: Elaboración propia, 2018.

En todo el periodo estudiado y para los dos modelos, la amplitud térmica de la temporada cálida parece mantenerse, mientras que en la temporada fría la temperatura máxima parecería aumentar más que la mínima.

4.2.1.4 Proyección de precipitación

En el caso de la *precipitación* anual acumulada (a la que se restó la climatología), como se aprecia en la Figura 20, no se identifican cambios. Por esta razón se realizó el estudio por temporada (Figura 21). El análisis muestra que los cuatro modelos proyectan un aumento mayor en la temporada cálida que en la fría, independientemente del periodo o escenario. En este sentido, cabe señalar que la disminución observada para el modelo CMIP5-CNRM-CM5 en el RCP 8.5 para el periodo 28/4/2036-14/10/2039 se debe a una falta de proyecciones de la que se desconoce el motivo.

Figura 20. Evolución de la precipitación con respecto a la climatología

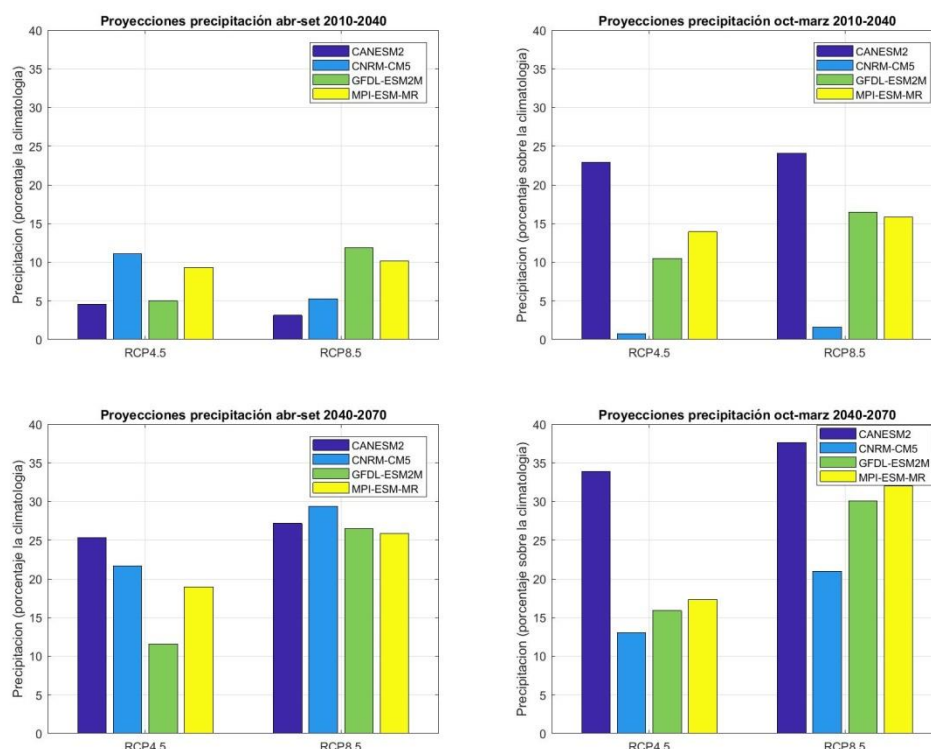


Fuente: Elaboración propia, 2018.

Con respecto a los escenarios para el periodo 2010-2040, no se observa una diferencia considerable, mientras que para el periodo 2040-2070 se encuentran cambios apreciables entre el RCP 4.5 y el RCP 8.5 en verano.

Si se comparan los resultados de cada periodo, se proyecta un mayor aumento en la precipitación en 2040-2070 que en 2010-2040, con una diferencia que llega a ser de entre 10 % y 20 % entre un periodo y otro.

Figura 21. Variación de la precipitación



Fuente: Elaboración propia, 2018.

Observando los resultados para la temporada fría, el aumento en el periodo 2010-2040 para ambos RCP es de entre 5 % y 10 %, mientras que para el periodo 2040-2070, en el caso del RCP 4.5 se proyecta un aumento de entre 10 % y 25 % y para el RCP 8.5, de entre 25 % y 30 %. En cambio, para la temporada cálida en el periodo 2010-2040 y en ambos escenarios, el aumento es de entre 10 % y 25 %. Para el periodo 2040-2070 y el RCP 4.5, se proyecta un aumento de entre un 15 % y 35 % y para el RCP 8.5, de entre 20 % y casi 40 %.

4.2.2 Evolución de extremos

4.2.2.1 Indicador de olas de calor

Se realizó un estudio de la posible evolución de las olas de calor, definidas como tres o más días consecutivos con temperatura máxima mayor al valor considerado como índice de extremo dependiente de la desviación estándar y la media histórica para cada día.

En la Tabla 4 se muestra la cantidad máxima del índice de olas de calor proyectadas, independientemente de la estación, para cada periodo y escenario. Se seleccionó el máximo entre las estaciones y no la suma porque las olas de calor son fenómenos regionales no puntuales, lo que implica que si ocurrió una ola de calor en una localidad, probablemente en otra relativamente cercana también haya ocurrido, por lo tanto, al sumar existe el riesgo de contar un mismo evento varias veces.

Tabla 4. Indicador de olas de calor por modelo, escenario y periodo, expresado en cantidad de ocurrencias

Olas de calor	RCP 4.5 2010-2040	RCP 4.5 2040-2070	RCP 8.5 2010-2040	RCP 8.5 2040-2070
CMIP5-CANESM2	4	14	2	26
CMIP5-CNRM-CM5	3	6	5	9
CMIP5-GFDL-ESM2M	2	6	1	15
CMIP5-MPI-ESM-MR	2	4	3	5

Fuente: Elaboración propia, 2018.


Como se puede ver en la Tabla 4, en ambos escenarios RCP se observa una evolución creciente de la ocurrencia de olas de calor, independientemente del modelo.

En cuanto a los resultados, existe una gran variabilidad entre los modelos, que se acentúa para el escenario RCP 8.5. El modelo CANESM2 se aleja considerablemente de los otros, principalmente en el periodo 2040-2070, mientras que el modelo que menos cambios proyecta es el MPI-ESM-MR.

4.2.2.2 Indicador de heladas

En la Figura 22 se puede observar una gran dispersión en las simulaciones históricas para todos los modelos. Sin embargo, en la mayoría se aprecia una oscilación que muestra una evolución negativa de las heladas. Esta proyección es consistente con los resultados encontrados por De Mello (2013).

Figura 22. Heladas presentadas para los distintos modelos en todo el periodo



Nota: El trazo continuo representa el ajuste polinomial de orden 4, mientras que el marcado con círculos representa el resultado en bruto.

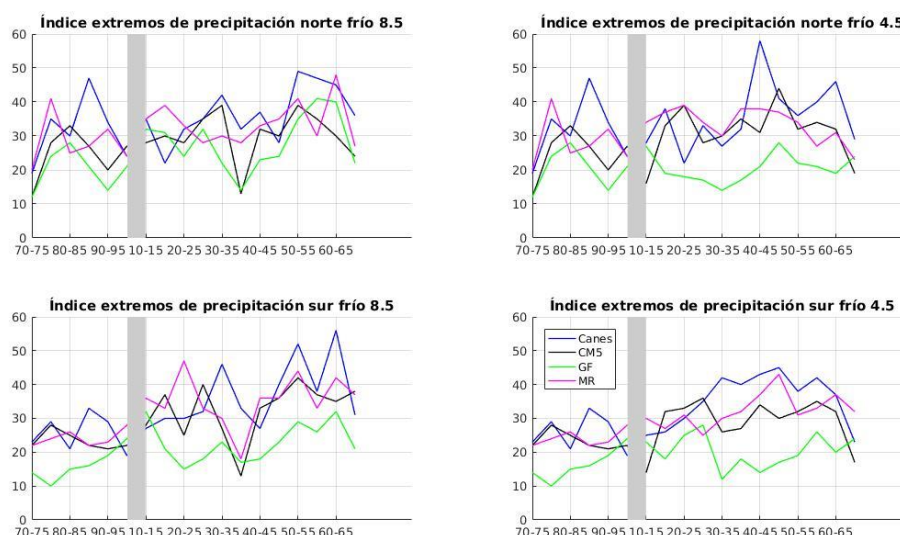
Fuente: Elaboración propia, 2018.

No se aprecia una diferencia significativa entre los RCP 4.5 y 8.5. Sin embargo, sí se observa una gran variabilidad entre los distintos modelos, lo que hace imposible la determinación de un margen para la ocurrencia de heladas. Por ejemplo, para el CANESM2 y el MPI-ESM-MR en ambos escenarios se observa una evolución negativa de la cantidad de heladas, mientras que el GFDL-ESM2M proyecta que la ocurrencia de heladas casi no cambiará y el CNRM-CM5 en el escenario RCP 4.5 casi no muestra cambios, aunque presenta una disminución en el RCP 8.5.

4.2.2.3 Eventos extremos de precipitación

Este estudio se hizo mediante la separación de las estaciones meteorológicas por región (norte y sur) y por temporada (cálida y fría). La Figura 23 muestra los resultados de las dos regiones y los dos RCP para la temporada fría, mientras que la Figura 24 ofrece los resultados para la temporada cálida. Como puede apreciarse, la cantidad de eventos con precipitación de más de 20 mm presenta una leve diferencia entre el RCP 4.5 y el RCP 8.5 para la temporada cálida en ambas regiones.

Figura 23. Índice de extremos de precipitación para la temporada fría



Nota: Gráfico 1: región norte, RCP 4.5. Gráfico 2: región norte, RCP 8.5. Gráfico 3: región sur, RCP 4.5. Gráfico 4: región sur, RCP 8.5.

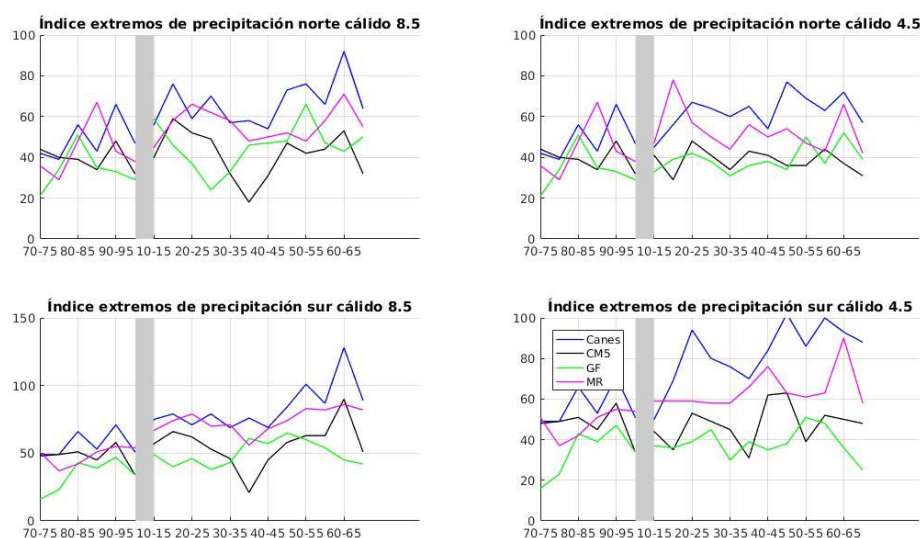
Fuente: Elaboración propia, 2018.

En particular, se observa una diferencia en las proyecciones entre el corto y mediano plazo, con mayor aumento para el mediano plazo en la región sur. Por otra parte, se encuentra mayor estabilidad en la ocurrencia de eventos extremos en la región norte. También se aprecia una mayor frecuencia para la temporada cálida, en la que se duplica la cantidad de ocurrencias con respecto al periodo frío.

Para comprobar la presencia de alguna señal de tendencia, se realizó el test Mann-Kendall a cada una de las curvas graficadas en la Figura 24 y la Figura 25. Los resultados obtenidos para los p-valores se encuentran en la Tabla 5, de la que se desprende que, al igual que en otros estudios, el modelo CANESM2 es el más extremo y muestra tendencia en la mayoría de los casos. El modelo CNRM-CM5 es el que menos posibilidad de tendencia parece proyectar, pero la falta de datos en el periodo 2036-2040 le quita confiabilidad.

En la Tabla 5 se observa que la posibilidad de que haya un aumento en la cantidad de eventos extremos puntuales de precipitación es mayor en la región sur que en la región norte para todos los modelos. Según lo esperable, también se aprecia que el RCP 8.5 ofrece más posibilidad de tendencia que el RCP 4.5.

Figura 24. Índice de extremos de precipitación para la temporada cálida



Nota: Gráfico1: región norte, RCP 4.5. Gráfico 2: región norte, RCP 8.5. Gráfico 3: región sur, RCP 4.5. Gráfico 4: región sur, RCP 8.5.

Tabla 5. P-valores (Mann-Kendall) de eventos extremo

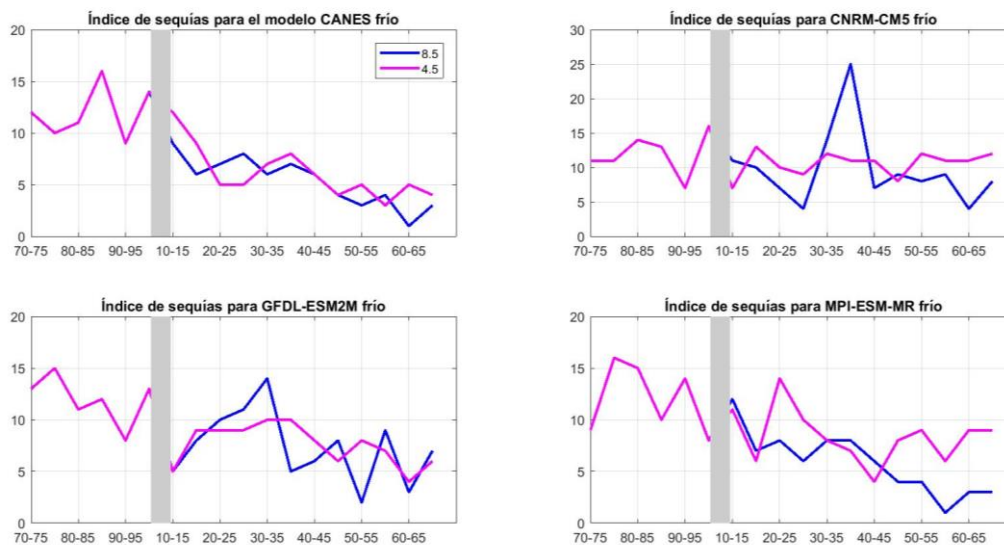
	CMIP5-CANESM2		CMIP5-CNRM-CM5	
	RCP 4.5	RCP 8.5	RCP 4.5	RCP 8.5
Norte temporada cálida	0.01	0.01	0.47	0.90
Norte temporada fría	0.17	0.05	0.10	0.10
Sur temporada cálida	0.00	0.00	0.73	0.15
Sur temporada fría	0.01	0.00	0.11	0.01
	CMIP5-GFDL-ESM2M		CMIP5-MPI-ESM-MR	
	RCP 4.5	RCP 8.5	RCP 4.5	RCP 8.5
Norte temporada cálida	0.06	0.04	0.47	0.05
Norte temporada fría	0.68	0.06	0.82	0.15
Sur temporada cálida	0.50	0.02	0.00	0.00
Sur temporada fría	0.05	0.01	0.00	0.01

Fuente: Elaboración propia, 2018.

4.2.2.4 Indicador de déficit hídrico

En la Figura 25 y la Figura 26 se representa la cantidad de meses en la franja correspondiente a déficit hídrico, agrupados cada cinco años para mejorar la visualización.

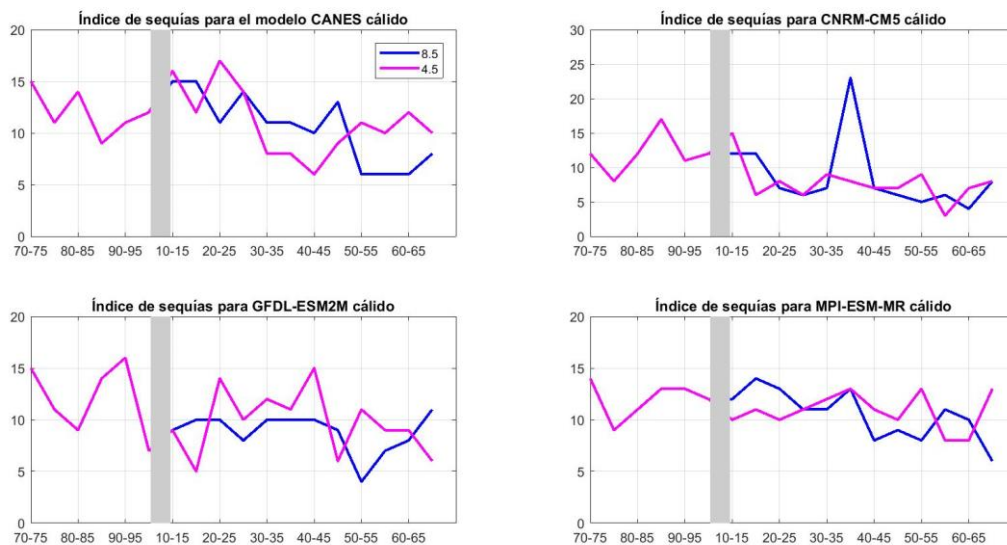
Figura 25. Déficit hídrico en temporada fría



Nota: En rosa aparece el RCP 4.5 y en azul el RCP 8.5.

Fuente: Elaboración propia, 2018.

Figura 26. Déficit hídrico en temporada cálida



Nota: En rosa aparece el RCP 4.5 y en azul el RCP 8.5.

Fuente: Elaboración propia, 2018.

Tanto en la Figura 25 como en la Figura 26 se aprecia una disminución en la cantidad casos, independientemente del modelo. Se observa que la frecuencia de déficit hídrico por mes cada cinco años siempre es inferior a los quince casos, excepto alguna situación puntual. Cabe mencionar que se consideran meses secos y no periodos consecutivos. Por otra parte, no parece haber mucha diferencia entre los distintos escenarios, salvo para algunos modelos en la temporada fría.

Al igual que para los eventos extremos puntuales, se realizó el test Mann-Kendall, que arrojó que la temporada fría presenta una posibilidad de tendencia mucho mayor que la cálida. Se obtuvieron en todos los modelos p-valores menores a 0,05, por lo que la posibilidad de tendencia en estas series es superior al 95 % para ambos RCP. Para la temporada cálida y el RCP 8.5 todos los modelos indicarían al 90 % la posibilidad de tendencia. Para el RCP 4.5 los resultados no son significativos (se encuentran p-valores de entre 0,15 y 0,40). Esto último indica la importancia de los test de significancia, ya que su aplicación permitió ver si las tendencias eran significativas, pero también comprobar si realmente eran similares los resultados de los distintos RCP.

5. Conclusiones

Tanto para el caso de las temperaturas como para el de la precipitación, las predicciones permiten identificar una fuerte correlación con la humedad específica. La variable precipitación, además, presenta una buena correlación, en comparación con las demás variables, con las velocidades horizontales en el nivel de geopotencial de 700 hPa y con el geopotencial al mismo nivel. Las temperaturas máxima y mínima muestran una fuerte correlación con el geopotencial en niveles altos, por ejemplo, 500 hPa y 250 hPa. También tienen gran correlación con la velocidad meridional, mientras que la velocidad zonal no aporta mucho. Se encontró mayor estabilidad para la temperatura mínima que para la máxima; por ejemplo, al seleccionar solamente la humedad específica, se llegó a valores altos de correlación.

Con respecto a las proyecciones climáticas, se vio que el modelo CANESM2 presenta los valores más extremos, por lo que se puede utilizar como indicador de los peores escenarios esperables considerando una evolución como la que contemplan los RCP.

En cuanto a las temperaturas, en ambas se observó una evolución significativa de aumento en las temporadas cálida y fría, aunque la tendencia es más pronunciada en la temporada fría. A corto plazo casi no existe diferencia entre los escenarios, pero a mediano plazo se hay un cambio mayor en el RCP 8.5. A su vez, al observar las proyecciones de precipitación, si bien se encontró aumento para todos los casos, es mayor en la temporada cálida que en la fría.

Si se comparan las proyecciones de temperatura mínima y máxima, se puede decir que la amplitud térmica, o sea, la diferencia entre temperatura máxima y mínima, parece ser mayor en la temporada fría. Esto se debe a un mayor crecimiento de la temperatura máxima respecto a la mínima.

En general, los índices de extremos resultan de situaciones de aumento de temperatura. Se esperaría una menor cantidad de heladas y una mayor cantidad de olas de calor. Además, las proyecciones de temperatura máxima, mínima y media y precipitación son positivas. Al estudiar los eventos extremos de precipitación no se pudo llegar a conclusiones claras. Se observó un leve aumento en la región sur, mientras que en la región norte se encontró más estabilidad. En el caso de los eventos extremos puntuales de precipitación, se duplican los casos en la temporada cálida con respecto a la fría. El indicador de déficit hídrico utilizado muestra que podría darse una disminución de estos eventos, más acentuada en la temporada fría.

Bibliografía

- Benestad, R. E. (2004). Empirical-statistical downscaling in climate modeling. *Eos*, 85(42): 417-422.
- Bidegain, M. (2016). Escenarios climáticos futuros sobre Uruguay. Ponencia presentada en el *Simposio Biodiversidad y salud. Especies exóticas invasoras*, Montevideo, 29 de agosto.
- Caorsi, M. L.; Cruz, G.; Terra, R.; y Astigarraga, L. (2018). Estudio de la variabilidad climática en la cuenca lechera del SW del Uruguay para el período 1939-2011. *Agrociencia Uruguay*, 22(1): 116-123.
- Chu, J. L.; Kang, H.; Tam, C. Y.; Park, C.K.; Chen, C. T. (2008). Seasonal forecast for local precipitation over northern Taiwan using statistical downscaling. *Journal of Geophysical Research: Atmospheres*, 113(D12): D12118.
- Díez, E.; Primo, C.; García-Moya, J. A.; Gutiérrez, J. M.; y Orfila, B. (2005). Statistical and dynamical downscaling of precipitation over Spain from DEMETER seasonal forecasts. *Tellus*, 57(3): 409-423.
- De Mello, S. (2013). *Estudio climatológico y regionalización de heladas meteorológicas en Uruguay*. Tesis de Licenciatura en Ciencias de la Atmósfera. Facultad de Ciencias-Facultad de Ingeniería, Universidad de la República.
- Downscaling Santander MetGroup (s/f). Sitio web. Disponible en: <https://meteo.unican.es/downscaling/intro.html> [Consultado: 14 de diciembre de 2018].
- Feddersen H. U.; y Andersen, A. (2005). A method for statistical downscaling of seasonal ensemble predictions. *Tellus*, 57(3): 398-408.
- Frich, P.; Alexander, L. V.; Della-Marta, P.; Gleason, B.; Haylock, M.; Klein Tank, A. M. G.; y Peterson, T. (2002). Observed coherent changes in climatic extremes during the second half of the twentieth century. *Climate Research*, 19(3): 193-212.
- Fundación para la Investigación del Clima (2019). *Descripción de la metodología de downscaling estadístico* [en línea]. Disponible en: <https://www.ficlima.org> [Consultado: 8 de marzo de 2019].
- Haylock, M. R.; Peterson, T. C.; Alves, L. M.; Ambrizzi, T.; Anunciação, M. T.; Baez, J.; Barros, B. R.; Berlato, M. A.; Bidegain, M.; Coronel, G.; Corradi, V.; García, V. J.; Grimm, A. M.; Karoly, D.; Marengo, J. A.; Marino, M. B.; Moncunill, D. F.; Nechet, D.; Quintana, J.; Rebello, E.; Rusticucci, M.; Santos, J. L.; Trebejo, I.; y Vincent, L. A. (2006). Trends in total and extreme South American rainfall in 1960-2000 and links with sea surface temperature. *Journal of Climate*, 19(8): 1490-1512.
- INIA (s/f). Red de estaciones automáticas [en línea]. Disponible en: <http://www.inia.org.uy/online/site/641458I1.php> [Consultado: 14 de diciembre de 2018].

- Intergovernmental Panel on Climate Change (IPCC) (s/f). Report graphics [en línea].
Disponible en: <<https://www.ipcc.ch/report/>> [Consultado: 14 de diciembre de 2018].
- INUMET (s/f). Mapa de estaciones [en línea]. Disponible en:
<<https://inumet.gub.uy/ServCli/mapasEstaciones>> [Consultado: 14 de diciembre de 2018].
- INUMET (s/f). Mapa de precipitación media del Uruguay [en línea]. Disponible en:
<<https://www.inumet.gub.uy/clima/estadisticas-climatologicas>> [Consultado: 14 de diciembre de 2018].
- Kang, H.; An, K.-H.; Park, C.-K.; Solis, A. L. S.; y K. Stitthichivapak (2007). Multi-model output statistical downscaling prediction of precipitation in the Philippines and Thailand. *International Journal of Climatology*. 34(14): L15710.
- Murphy, J. (1999). An evaluation of statistical and dynamical techniques for downscaling local climate. *Journal of Climate*, 12(8): 2256-2284.
- Renom, M. (2009). *Temperaturas extremas en Uruguay. Análisis de la variabilidad temporal de baja frecuencia y su relación con la circulación de gran escala*. Tesis doctoral. Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires.
- Rojas, P. (2017). ¿Qué es un Modelo GCM-Modelos de Circulación General? [en línea].
Disponible en: <<https://www.ingeciv.com/que-es-un-modelo-gcm-modelos-de-circulacion-general>> [Consultado: 15 de marzo de 2019].
- Saravia, C.; Astigarraga, L.; Van Lier, E.; y Bentancur, O. (2011). Impacto de las olas de calor en vacas lecheras en Salto (Uruguay). *Agrociencia Uruguay*, 15(1): 93-102.
- Thornthwaite, C.; y Mather, J. (1957). *Instructions and tables for computing potential evapotranspiration and the water balance*. Nueva Jersey: Centerton.
- USAID-ARCC (2014). *A review of downscaling methods for climate change projections*. Washington: USAID.
- Vincent, L. A.; Peterson, T. C.; Barros, V. R. ; Marino, M. B. ; Rusticucci, M. ; Carrasco, G. ; Ramírez, E. ; Alves, L. M.; Ambrizzi, T.; Berlato, M. A.; Grimm, A. M.; Marengo, J.A.; Molion, L.; Moncunill, D. F.; Rebello, E.; Anunciação, M. T.; Quintana, J.; Santos, J. L.; Baez, J.; Coronel, G.; García, J.; Trebejo, I.; Bidegain, M.; Haylock, M. R.; y Karoly, D. (2005). Observed trends in indices of daily temperature extremes in South America 1960–2000. *Journal of Climate*, 18(23): 5011-5023.
- Von Storch, H.; y Zwiers, F.W. (1999). *Statistical Analysis in Climate Research*. Nueva York: Cambridge University Press.
- Von Storch, H.; Zorita, E.; y Cubasch, U. (1993). Downscaling of Global Climate Change Estimates to Regional Scales: An Application to Iberian Rainfall in Wintertime. *Journal of Climate*, 6(6): 1161-1171.
- Wetterhall, F.; Halldin, S. y Xu, C.-Y. (2005). Statistical downscaling of precipitation in Sweden using the analogue method. *Journal of Hydrology*, 306: 174-190.

Wilby, R. L.; Wigley, T. M. L.; Conway, D.; Jones, P. H.; Hewitson, B. C.; Main, J.; y Wilks, D. S. (1998). Statistical downscaling of general circulation model output: A comparison of methods. *Water Resources Research*, 34(11): 2995-3008.

Wilks, D. (2011). *Statistical methods in the atmospheric science*. Oxford: Academic Press.



Fomentado por el:



Ministerio Federal
de Medio Ambiente, Protección de la Naturaleza,
Obras Públicas y Seguridad Nuclear

en virtud de una resolución del
Parlamento de la República Federal de Alemania