

# Comparación de series mensuales de precipitación y temperaturas de los Modelos CMIP6 para Guatemala

*Monthly series comparison of precipitation and temperatures of the CMIP6 Models for Guatemala*

Paris Rivera <sup>1\*</sup>, Eduardo Herrera<sup>2</sup>, Wener Ochoa<sup>3</sup>

<sup>1</sup>Instituto de Investigaciones de Ingeniería, Matemática y Ciencias Físicas, Universidad Mariano Gálvez de Guatemala

<sup>2</sup>Facultad de Instrumentación Electrónica, Universidad Veracruzana, México

<sup>3</sup>Escuela de Estudios de Postgrado, Facultad de Ingeniería, Universidad de San Carlos de Guatemala

\*Autor al que se dirige la correspondencia: [parysryver@gmail.com](mailto:parysryver@gmail.com)

Recibido: 16 de octubre 2021 / Revisión: 19 de septiembre 2022 / Aceptado: 17 de octubre 2022

## Resumen

Se comparan las métricas de 37 modelos climáticos globales (GCMs, por sus siglas en inglés) de la Fase 6 del Proyecto de Intercomparación de Modelos Acoplados (CMIP6) con el objetivo de simular el clima de Guatemala del periodo de 1971 al 2014. La temperatura y precipitación mensual fue comparada con los datos de observación de la Unidad De Investigación Climática de la Universidad del este de Anglia (CRU). Se generó un ranking de modelos basado en la menor distancia entre tres dimensiones basado en tres métricas; Coeficiente de Correlación de Pearson (CCP), Error medio cuadrático (RMSE) y Desviación estándar (DS). Este ordenamiento coincide con los mejores valores de eficiencia Nash-Sutcliffe (NSE) para temperatura y eficiencia Kling-Gupta (KGE) para la precipitación, demás se calculan las métricas; coeficiente de correlación de Spearman (CCS), errores de sesgo medio (MBE) y el absoluto medio (MAE). Para precipitación los primeros 5 modelos presentan valores KGE de entre 0.5 y 0.7, el CCP y CCS entre 0.7 a 0.8 comparados con CRU. Para temperatura los primeros 5 modelos presenta valores de NSE de entre 0.5 a 0.6, CCP y CCS de 0.8. Los modelos sobreestiman levemente la temperatura y subestiman la precipitación. Los modelos con mejor habilidad fueron CIESM para temperatura y el modelo IPSL-CM6A-LR para precipitación. Adicionalmente se compara el promedio de 66 estaciones locales con CRU, presentando un KGE de 0.51, CCP de 0.77 para precipitación y NSE de -0.17 y un CCP de 0.20 para temperatura. Finalmente, se presenta una tabla con los 10 primeros modelos para cada variable.

Palabras clave: Modelo climáticos, precipitación, temperatura

## Abstract

Metrics from 37 global climate models (GCMs) from Phase 6 of the Coupled Model Intercomparison Project (CMIP6) with the purpose of simulating the climate of Guatemala from 1971 to 2014. Monthly temperature and precipitation were compared with data from observation of the Climatic Research Unit of the University of East Anglia (CRU). A ranking of models was generated based on the shortest distance between three dimensions based on three metrics; Pearson's Correlation Coefficient (PCC), Root Mean Square Error (RMSE), and Standard Deviation (SD). This ordering coincides with the best values of Nash-Sutcliffe efficiency (NSE) for temperature and Kling-Gupta efficiency (KGE) for precipitation; other metrics are calculated; Spearman's correlation coefficient (CCS), mean bias errors (MBE), and mean absolute error (MAE). For precipitation, the first 5 models present KGE values between 0.5 and 0.7, the CCP and CCS between 0.7 and 0.8 compared to CRU. For temperature, the first 5 models present NSE values between 0.5 to 0.6, CCP, and CCS of 0.8. The models slightly overestimate temperature and underestimate precipitation. The models with the best ability were CIESM for temperature and the IPSL-CM6A-LR model for precipitation. Additionally, the average of 66 local stations is compared with CRU, presenting a KGE of 0.51, CCP of 0.77 for precipitation, and NSE of -0.17, and a CCP of 0.20 for temperature. Finally, a table is presented with the first 10 models for each variable.

Keywords: Climatic model, precipitation, temperature



## Introducción

Los modelos climáticos globales (GCMs, por sus siglas en inglés) son una representación numérica del sistema climático basada en las propiedades físicas, químicas y biológicas de sus componentes. Estos se utilizan como herramienta de investigación para estudiar y simular el clima y para fines operativos, en particular predicciones climáticas mensuales, estacionales e interanuales (Panel Intergubernamental del Cambio Climático [IPCC], 2014). Las simulaciones de los modelos no son exactas y tienen limitaciones al momento de simular el clima local (Lupo & Kininmonth, 2013), por lo que antes de utilizarlos es necesario evaluar su habilidad para reproducir el clima local, comparando con bases de datos globales o locales de preferencia.

La nueva generación de modelos climáticos de CMIP6 que pertenecen a la sexta fase del Proyecto de Inter-comparación de Modelos Climáticos del World Climate Research Program (WCRPs), permiten la obtención de diversos modelos para diferentes variables meteorológicas en una región específica, además muestra importantes mejorías para detectar el comportamiento climático del mundo, considerados ahora como modelos climáticos de alta sensibilidad. Al mismo tiempo, la respuesta climática transitoria permanece sin cambios y el calentamiento histórico simulado es compatible con las observaciones (Voldoire et al., 2019). Actualmente las distintas instituciones de investigación del clima ya presentan análisis realizados a partir de datos de CMIP6, enfocados en la evaluación de su habilidad, así como la generación de proyecciones de cambio climático. La nueva versión de CMIP (CMIP6) se ha comparado con sus predecesoras para distintas variables y en diversas regiones, encontrando en general que los modelos CMIP6 tienen menor diferencia con las observaciones en comparación con los modelos CMIP5 (Shu et al., 2020).

Las generaciones CMIP (CMIP3, CMIP5 y CMIP6) se han caracterizado su mejora continua, a tal grado que algunos modelos CMIP6 detectan patrones de forzantes climáticos como la Oscilación del Atlántico Norte, Modo Anual del Hemisferio Norte y el Modo Anual del Sur (NAO, NAM y SAM, por sus siglas en inglés) (Fasullo et al., 2020). Las precipitaciones simuladas para la antártica a nivel continental y regional, la mediana de los modelos ERA5, tienen una mejora insignificante de CMIP5 a CMIP6 y también una mejora de la temperatura cerca de la superficie (Roussel et al., 2020). Algunas comparaciones entre modelos globales para distintas variables climáticas

mencionan que en general, no hay una mejora significativa de CMIP5 sobre CMIP3 (Lee et al., 2013). En tal sentido los modelos acoplados (CMIP5) comparados con la generación anterior (CMIP3) encuentran diferencias con los datos de reanálisis, lo que indica una incertidumbre considerable con respecto a su simulación (Sillmann et al., 2013).

Los GCMs han sido utilizados para evaluar las extensiones de hielo marino del Ártico y la Antártida. La media multi-modelo CMIP6 puede reproducir adecuadamente los ciclos estacionales de ambas extensiones Ártica y Antártica. En comparación con los modelos CMIP5, los modelos CMIP6 tienen menor diferenciales entre modelos en valores medios y tendencias de dichas extensiones (Shu et al., 2020). Los GCMs también se utilizan para el análisis de eventos extremos climáticos tales como los detenidos por el Equipo de Expertos en índices de cambio climático (ETCCDI). Los resultados muestran que los modelos CMIP6 generalmente capturan los patrones globales y regionales observados de temperaturas extremas con mejoras limitadas en comparación con los modelos CMIP5 (Kim et al., 2020). Los modelos CMIP6 no solo se usan para simular precipitación y temperatura sino para estudios de forzantes climáticos como la Onda Circumpolar Antártica (ACW por sus siglas en inglés), en este caso la presión atmosférica fue analizada, encontrando que la capacidad de los modelos para simular la variación de la presión atmosférica del mar es mejor en los modelos del CMIP6 que los modelos CMIP5 (Lu et al., 2020).

En general los modelos CMIP5 simulan la precipitación con menor errores y menor dispersión que los modelos CMIP3 en los patrones de precipitación anual y estival (Gulizia & Camilloni, 2015). Sin embargo, en la parte oriental del sureste de América del Sur, un conjunto de modelos CMIP5 múltiples subestima el ciclo anual de precipitaciones y las sequías (Penalba & Rivera, 2016), pero capturan adecuadamente las variaciones de precipitación sobre la Pampa Occidental Argentina (Maenza et al., 2017). En África Oriental la media del conjunto de modelos CMIP6 en términos generales muestra un mejor rendimiento en la simulación del ciclo medio anual local de precipitación en comparación con los modelos CMIP5 (Ayugi et al., 2021), coincidiendo con Vinod y Agilan (2022), para el área de India.

Los datos CRU se utilizan para realizar las comparaciones de los GCMs en todo el mundo, en el caso de estudios para Sudamérica en la que se logró determinar el mejor grupo de modelos para esa región

(Lovino et al., 2018). Para esta región Palomino-Lemus y colaboradores (2015) también realizaron comparaciones con otros datos de reanálisis, como los de la National Centers for Environmental Prediction (NCEP por sus siglas en inglés). Evaluaciones de los modelos CMIP5 en el noreste de América del sur, encuentran que, todos los modelos reproducen adecuadamente los principales modos de variabilidad asociada con el Fenómeno del Niño y la Oscilación del Sur (ENOS) y con la del Atlántico tropical, sin embargo algunos modelos tienden a sobreestimar la varianza asociada con el primer modo (Palomino-Lemus et al., 2015). Pero es de hacer notar que los proyectos CMIP, mejoran continuamente, gracias a los adelantos tecnológicos y científicos, tal es el caso de un análisis en la región del Himalaya en donde se evaluaron los modelos globales y en general, los GCMs del CMIP5 fueron más hábiles en simular el ciclo anual de la variabilidad interanual en comparación con GCMs del CMIP3 (Meher et al., 2017). En general los modelos aún tienen dificultades para reproducir los patrones temporales, para Agyekumy y colaboradores (2022), la realización de promedios de conjunto de los modelos muestra mejores rendimientos en comparación con modelos individuales en la variable de temperatura principalmente.

Para Centroamérica el grupo multi-modelo CMIP5 tiene un rendimiento razonablemente bueno en la reproducción de la variabilidad observada, los modelos pueden reproducir la variabilidad observada en el Pacífico oriental y la mayoría de los modelos capturan la Sequía de Medio Verano sobre Centro-

américa (Sheffield et al., 2013). En el caso del grupo multi-modelos CMIP6, existen sesgos en las magnitudes de precipitación, pero en general capturan muy bien las características generales de la variación estacional en la región de Centroamérica (Almazroui et al., 2021). El ciclo anual de temperaturas observadas y simuladas por los modelos CMIP6 tienen una coherencia general, pero con un sesgo cálido de entre 0.4 a 0.5 °C para la región Centroamericana, respecto a CRU en el verano (JJA).

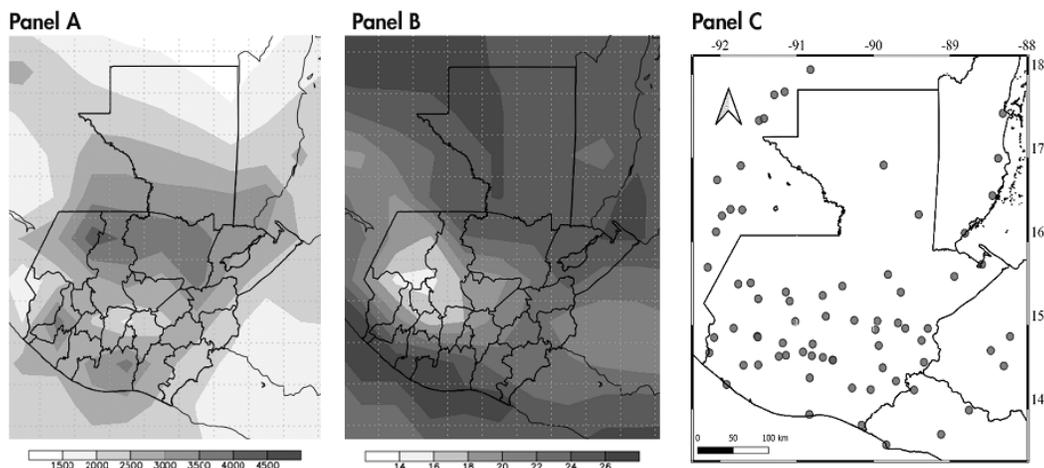
Este estudio compara las series mensuales de precipitación y temperatura de 37 GCMs del proyecto CMIP6 con la base de datos de la Unidad de Investigación Climática de la Universidad del este de Anglia de Inglaterra (CRU), por medio de varias métricas de dispersión aplicadas a los GCMs, para determinar los modelos con mejor rendimiento (Lovino et al., 2018; Palomino-Lemus et al., 2015). El objetivo es encontrar el grupo de modelos globales más adecuados para simular el clima de Guatemala para desarrollar futuras investigaciones.

## Materiales y Métodos

La comparación que se realizó considera las series mensuales de precipitación y temperatura de un recorte espacial en el dominio: 13.5°N a 18°N y 88.1°W a 92.5°W, coordenadas que contienen dentro al territorio de Guatemala y parte de otros países centroamericanos (Figura 1).

**Figura 1**

*Área de evaluación seleccionada (13.5°N a 18°N y 88°W a 92.5°W)*



*Nota.* Panel A promedio anual de precipitación (mm) CRU TS 4.02; Panel B promedio de temperatura anual (°C) CRU TS 4.02 y Panel C Región con las estaciones locales.

## Datos de modelos y de observación

Se utilizan las salidas de los modelos del periodo 1971-2014 de 37 GCMs (Tabla 1) integrados en la base de datos del proyecto CMIP6, que corresponden a las nuevas generaciones de los modelos utilizados en el AR6- IPCC de diferentes centros de investigación y modelación climática del mundo y la base de datos de referencia pertenece al grupo de datos de reanálisis del Climatic Research Unit (CRU), conjunto de datos climáticos con una cuadrícula de 0.5° de latitud por 0.5° de longitud en todos los dominios terrestres del mundo excepto la Antártida (Harris et al., 2020).

Los datos utilizados de CMIP6 corresponden a los experimentos *historical* según la codificación del

World Climatic Research Program (WCRP) las simulaciones utilizadas son las r1i1p1, donde *r* es el primer número de realización, *i* es el indicador del método de inicialización, y *p* el número de física perturbado. Más detalles se encuentran en Taylor y colaboradores (2012), la resolución espacial y temporal de entre 100 a 200 km<sup>2</sup> y mensual respectivamente. Entre estos se encuentran modelos acoplados océano-atmósfera (AOGCM por sus siglas en inglés), los modelos del sistema terrestre (ESM por sus siglas en inglés) y los modelos con procesos químicos atmosféricos (ChemAO y ChemESM por sus siglas en inglés). Además, se compara el promedio de 66 estaciones locales dentro de área de estudio, 43 de Guatemala, 12 de México y 4 de Belice, 4 de El Salvador y 3 de

**Tabla 1**

*Modelos CMIP6 utilizados, nombres, instituciones, resolución y referencias*

No.	Modelo CMIP6	Institución	Resolución espacial (km)	Referencia
1	ACCESS-CM2	Australian Community Climate and Earth-System Simulator	250	Dix et al. (2019)
2	AWI-CM-1-1-MR	Alfred Wegener Institute for Polar and Marine Research	100	Semmler et al. (2018)
3	BCC-CSM2-MR	Beijing Climate Center, Climate System Model	100	Wu et al. (2019)
4	BCC-ESM1	BBC, CMA. Beijing Climate Center Climate System Model.	250	Zhang et al. (2018)
5	CAMS-CSM1-0	China Meteorologic Administration	100	Rong et al. (2019)
6	CanESM5	Canadian Centre for Climate Modeling and Analysis	500	Swart et al. (2019)
7	CESM2	NSF-DOE-NCAR, National Science Foundation federally funded research and development center. National Center for Atmospheric Research.	100	Danabasoglu (2019)
8	CESM2-FV2	NSF-DOE-NCAR, National Science Foundation federally funded research and development center. National Center for Atmospheric Research.	250	Danabasoglu (2019)
9	CESM2-WACCM	NSF-DOE-NCAR, National Science Foundation federally funded research and development center. National Center for Atmospheric Research.	100	Danabasoglu (2019)
10	CESM2-WACCM-FV2	NSF-DOE-NCAR, National Science Foundation federally funded research and development center. National Center for Atmospheric Research.	250	Danabasoglu (2019)
11	CIESM	Department of Earth System Science, Tsinghua University	100	Huang (2019)
12	E3SM-1-0	Earth System Grid Federation	100	Bader et al. (2019)
13	E3SM-1-1	Department of Energy, Lawrence Livermore National Laboratory	100	Bader et al. (2019)
14	EC-Earth3	EC-Earth Consortium	100	(EC-Earth) (2019)
15	EC-Earth3-Veg	EC-Earth Consortium	100	(EC-Earth) (2019)

**Tabla 1 (continuación)**

No.	Modelo CMIP6	Institución	Resolución espacial (km)	Referencia
16	FGOALS-f3-L	LASG, Institute of Atmospheric Physics, Chinese Academy of Sciences	100	YU (2019)
17	FGOALS-g3	LASG, Institute of Atmospheric Physics, Chinese Academy of Sciences	250	Li (2019)
18	FIO-ESM-2-0	FIO-SOA First Institute of Oceanography State Oceanic Administration	100	Song et al. (2019)
19	GFDL-ESM4	NOOAA-GFDL, National Oceanic and Atmospheric Administration, Geophysical Fluid Dynamics Laboratory	100	Krasting et al. (2018)
20	GISS-E2-1-G	NASA-GISS. National Aeronautics and Space Administration. Goddard Institute for Space Studies	250	(NASA/GISS) (2018)
21	GISS-E2-1-G-CC	NASA-GISS. National Aeronautics and Space Administration. Goddard Institute for Space Studies.	250	(NASA/GISS) (2018)
22	GISS-E2-1-H	National Aeronautics and Space Administration. Goddard Institute for Space Studies.	250	(NASA/GISS) (2018)
23	INM-CM4-8	INM. Russian Institute for Numerical Mathematics Climate Model	100	Volodin et al. (2019)
24	INM-CM5-0	INM. Russian Institute for Numerical Mathematics Climate Model.	100	Volodin et al. (2019)
25	IPSL-CM6A-LR	Institut Pierre-Simon Laplace	250	Boucher et al, (2018)
26	KACE-1-0-G	National Institute of Meteorological Science	250	Byun et al. (2019)
27	MCM-UA-1-0	The University of Arizona	250	Stouffer (2019)
28	MIROC6	JAMSTEC. Japan Agency for Marine-Earth Science and Technology.	250	Tatebe & Watanabe (2018)
29	MPI-ESM-1-2-HAM	MPI Max Planck Institute	250	Neubauner et al. (2019)
30	MPI-ESM1-2-HR	MPI Max Planck Institute	100	Jungclaus et al. (2019)
31	MPI-ESM1-2-LR	MPI Max Planck Institute	250	Wieners et al. (2019)
32	MRI-ESM2-0	Meteorological Research Institute	100	Yukimoto et al. (2019)
33	NESM3	Earth System Grid Federation	250	Cao & Wang (2019)
34	NorCPM1	EarthClim	250	Bentsen et al. (2019)
35	NorESM2-LM	NCC Norwegian Climate Centre	250	Seland et al. (2019)
36	NorESM2-MM	NCC Norwegian Climate Centre	100	Bentsen et al. (2019)
37	SAM0-UNICON	Global Climate Simulated by the Seoul National University Atmosphere Model Version 0 with a Unified Convection Scheme	100	Park & Shin (2019)

Honduras, este promedio está identificado en la tabla como “Región” (Figura 1C).

Los datos de referencia CRU están a una resolución de 0.5° y la resolución de las simulaciones de los modelos tiene resoluciones que van desde los 1 grados a 4 grados para la serie de 43 años, periodo 1971-2014.

## Procesamiento de datos

Para los recortes de la región en estudio de los modelos globales se utilizó el software GRADS (Doty & Kinter, 1995), que además permitió realizar los promedios de las series del área en estudio para cada modelo global de las variables de precipitación y temperatura mensual. Para dichas series se calcularon las siguientes métricas; error de sesgo medio (MBE); indica si una simulación de los GCMs sobreestima o subestima los datos observados, error absoluto medio (MAE) y raíz del error cuadrático medio (RMSE); los cuales representan la magnitud del error entre la serie simulada y la observada, descripción de estas métricas se puede encontrar en Willmott & Matsuura, 2005, la eficiencia de Nash-Sutcliffe (NSE); que proporciona información sobre la habilidad predictiva de las series simuladas como se explica en Nash y Sutcliffe, 1970; este coeficiente varía entre  $-\infty$  y 1, siendo 1 la puntuación perfecta de habilidad predictiva de la serie simulada, Moriasi y colaboradores (2007) sugirió que el rendimiento del modelo puede ser evaluado como “satisfactorio” si  $NSE > 0.5$  y “muy bueno” si  $NSE > 0.75$ , la desviación estándar (DS); proporciona información sobre, que tan bien se ajustan los modelos a la variabilidad de los datos observados, el coeficiente de correlación Pearson (CCP) al igual que el coeficiente de correlación de Spearman (CCS); proporcionan información sobre, que tan bien se ajustan los modelos al comportamiento de los datos observados en relación lineal y monótona respectivamente, el error medio cuadrático (RMSE); proporciona información sobre, qué tan cercano están los datos simulados de los datos observados y finalmente el coeficiente de eficiencia Kling-Gupta (KGE), esta medida de bondad de ajuste contempla la correlación, sesgo y variabilidad (Gupta et al., 2009), en este caso valores superiores a 0.5 se consideran buenos (Rogelis et al., 2016). Todas estas métricas se presentan en tablas para su comparación en un ranking de modelos. Cada una de estas métricas proporcionan información sobre la variabilidad, sesgo y predictibilidad de cada modelo respecto a los datos de referencia observados.

El diagrama de Taylor fue utilizado para mostrar de forma cualitativa el rendimiento aproximado de las predicciones de los modelos, con respecto a los valores de referencia. La similitud entre dos parámetros se cuantifica en términos de su coeficiente de CCP, la raíz del error cuadrático medio centrado (CRMS) y la amplitud de sus variaciones, que es representada por su desviación estándar (DS) de los modelos. En el diagrama los modelos ubicados próximos al punto señalado como “CRU” u “Obs” = observado corresponden a los modelos que mejor acuerdan con la referencia (Taylor, 2001).

Para el análisis comparativo se realiza gráficos interanuales y de ciclo anual para visualizar el sesgo que tiene los modelos respecto a las series de referencia. Se utilizan diagramas de dispersión entre CRU y; el mejor modelo según las métricas evaluadas; el promedio de estaciones locales y el promedio del conjunto de los 37 modelos, cada diagrama contiene el coeficiente de determinación ( $R^2$ ) en comparación con CRU y pendiente ( $m$ ) en comparación con una  $m$  1:1.

Para tener una medida cuantitativa de los que expresa el Diagrama de Taylor se utilizó la distancia mínima entre dos puntos en un sistema de coordenadas cartesianas tridimensional, en donde  $x$ ,  $y$  y  $z$  serán representadas en el cálculo de las métricas; DS, CCP y CRMSE respectivamente. La distancia entre dos puntos cualesquiera  $P1(x1, y1, z1)$  y  $P2(x2, y2, z2)$  es:

$$d(p1, p2) = \sqrt{(x2 - x1)^2 + (y2 - y1)^2 + (z2 - z1)^2} \quad (1)$$

Esta medida generó el ranking de los modelos con menor distancia respecto a los datos de referencia, es decir la menor distancia entre dos puntos.

## Resultados

### Simulación histórica de precipitación mensual, 43 años (1971-2014)

El ranking de modelos se puede ver en la Tabla 2. En ella se muestran las métricas de los 37 modelos además del promedio de estaciones locales “Región”. En términos generales las simulaciones de los primeros 10 modelos reproducen muy bien la serie comparada con los datos CRU, los rangos de CCP y CCS oscilan entre 0.7 a 0.8. Las métricas RMSE y MAE son variables entre los modelos presentando se entre el rango

de 81 a 129 y de 61 a 98 respectivamente. La métrica MBE sugiere que la mayoría de los GCMs tienden a subestimar la precipitación (Lovino et al., 2018). En términos generales los errores estadísticos son altos y el NSE son relativamente bajas. Pero las mejores eficiencias están en los primeros 5 modelos los cuales varían de 0.4 a 0.6 en NSE y 0.6 a 0.7 en KGE.

Las series de tiempo de precipitación anuales de la serie de referencia CRU, (promedio de 62 estaciones), y modelos se presentan en la Figura 2, los GSMs en rango intermodelo (área gris).

El promedio de 37 modelos subestima la precipitación observada en un 48% en promedio, el modelo IPSL-CM6A-LR subestima en solo un 4% y el promedio de 71 estaciones locales subestima un 20%. Los porcentajes se estiman como,

$$\%prc = \left[ \frac{s-o}{o} \right] * 100, \quad (2)$$

siendo S y O los valores promedio simulados y observados de las series de tiempo respectivamente.

**Tabla 2**

*Métricas de comparación estadística entre las series temporales de precipitación mensual observada por CRU, simulaciones CMIP6 y promedio de estaciones locales "Región", para el periodo (1971-2014). Ranking, Modelo, Distancia, KGE, NSE, CCP, CCS, RMSE, DS (mm/mes), MAE y MBE en (mm/mes)*

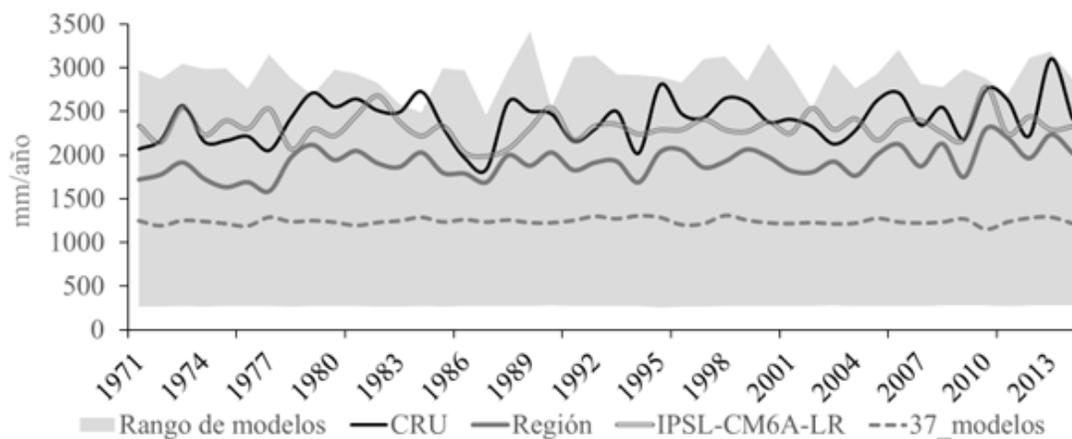
	Modelos CMIP6, CRU y Región	Distancia	KGE	NSE	CCP	CCS	RMSE	DS	MAE	MBE
	CRU	0.00	1	1	1	1	0	142.04	0	0
1	IPSL-CM6A-LR	83.58	0.77	0.67	0.82	0.80	81.26	122.45	61.19	-7.73
2	FGOALS-g3	97.57	0.72	0.53	0.82	0.81	97.39	148.03	73.75	41.58
3	MRI-ESM2-0	104.68	0.65	0.47	0.77	0.80	103.50	126.33	75.41	-47.98
4	NorESM2-MM	108.86	0.59	0.46	0.77	0.79	104.01	109.89	74.08	-51.99
5	CanESM5	110.33	0.68	0.40	0.75	0.81	110.16	148.07	78.96	-38.87
6	NESM3	117.80	0.56	0.33	0.76	0.80	116.40	123.94	88.09	-70.13
7	CESM2-WACCM	130.84	0.48	0.19	0.66	0.75	127.70	113.54	92.21	-68.26
8	MIROC6	137.08	0.41	0.16	0.71	0.73	129.79	97.95	98.51	-82.45
9	NorESM2-LM	138.27	0.41	0.13	0.73	0.75	132.20	101.53	98.01	-89.83
10	CESM2	143.64	0.38	0.07	0.65	0.73	137.17	99.42	101.25	-84.34
11	BCC-ESM1	144.92	0.48	-0.04	0.66	0.78	144.60	151.73	111.85	-79.50
12	SAM0-UNICON	145.62	0.33	0.14	0.67	0.68	131.24	78.93	94.03	-77.00
13	GFDL-ESM4	147.03	0.34	0.07	0.69	0.74	136.98	88.62	99.92	-89.97
14	KACE-1-0-G	148.94	0.34	0.01	0.69	0.77	140.95	93.90	106.30	-96.78
15	EC-Earth3	150.69	0.31	0.04	0.72	0.78	139.32	84.62	102.87	-96.76
16	EC-Earth3-Veg	150.92	0.32	0.01	0.67	0.77	140.99	88.20	102.91	-93.96
17	CIESM	156.15	0.28	-0.08	0.58	0.72	147.38	90.44	107.88	-91.09
18	MIROC-ES2L	157.51	0.26	-0.02	0.67	0.72	143.63	77.38	107.37	-96.18
19	GISS-E2-1-G	157.59	0.26	-0.04	0.61	0.67	144.61	79.42	105.51	-90.16
20	GISS-E2-1-G-CC	157.65	0.26	-0.06	0.57	0.63	146.42	83.58	107.17	-88.40
21	FIO-ESM-2-0	159.23	0.23	0.06	0.66	0.72	137.56	61.86	97.68	-81.07
22	MCM-UA-1-0	163.68	0.45	-0.27	0.53	0.59	160.10	176.11	114.42	-28.43

**Tabla 2 (continuación)**

	Modelos CMIP6, CRU y Región	Distancia	KGE	NSE	CCP	CCS	RMSE	DS	MAE	MBE
23	MPI-ESM1-2-LR	167.75	0.20	-0.13	0.75	0.77	151.16	69.31	116.36	-112.42
24	MPI-ESM1-2- HAM	177.18	0.15	-0.32	0.69	0.74	163.16	72.96	127.82	-123.93
25	CESM2-FV2	179.58	0.14	-0.42	0.54	0.59	169.32	82.21	128.24	-120.19
26	FGOALS-f3-L	185.05	0.07	-0.38	0.53	0.59	166.45	61.17	124.10	-114.07
27	E3SM-1-1	188.11	0.08	-0.49	0.56	0.62	173.35	69.00	132.37	-127.27
28	CAMS-CSM1-0	196.11	0.03	-0.44	0.74	0.77	170.38	44.94	130.42	-127.86
29	E3SM-1-0	196.40	0.03	-0.60	0.60	0.68	179.32	61.95	138.22	-136.56
30	BCC-CSM2-MR	196.60	0.01	-0.59	0.54	0.73	179.07	60.90	136.55	-132.16
31	GISS-E2-1-H	197.99	-0.01	-0.67	0.44	0.64	183.13	66.81	137.18	-131.51
32	CESM2-WACCM- FV2	199.18	0.00	-0.68	0.51	0.53	183.90	65.52	140.08	-137.51
33	INM-CM5-0	204.63	-0.14	-0.74	0.25	0.26	187.21	59.41	135.77	-124.66
34	NorCPM1	250.55	-0.34	-1.37	0.44	0.45	218.63	19.66	172.57	-172.46
35	INM-CM4-8	266.94	-0.44	-1.56	0.43	0.40	227.14	1.80	178.19	-177.95
36	MPI-ESM1-2-HR	267.12	-0.48	-1.56	0.35	0.33	227.15	1.49	178.06	-177.79
37	ACCESS-CM2	267.29	-0.52	-1.57	0.26	0.23	227.56	1.83	178.54	-178.26
	Región	115.52	0.51	0.47	0.77	0.80	103.43	90.60	74.11	-47.32

**Figura 2**

Serie anual de precipitación anual (mm/año) observada por CRU y simulada por los CIMIP6, modelo IPSL-CM6A-LR y Región



Se puede observar en la Figura 2 que el rango de 37 modelos (área gris) tiene una amplitud amplia y su promedio (línea gris discontinua) subestima los datos observados CRU, el promedio Región (línea gris oscuro) queda por debajo y el modelo IPSL-CM6A-LR (línea doble) es el que mejor se ajusta de todos los modelos. La serie de datos CRU y algunos modelos detecta los máximos de precipitación local que existieron en 1998 con el huracán Mitch y en 2010 con la Tormenta Agatha.

Los comparativos del ciclo anual de precipitación se puede observar la Figura 3, El rango de 37 modelos (área gris) tiene gran amplitud y su promedio subestima las observaciones CRU (línea negra) durante todo el año, los meses más cercanos son los meses de enero, febrero, marzo y diciembre, coincidiendo con parte de invierno austral. Algunos autores como Lovino y colaboradores (2018), Penalba y Rivera (2016) y Maenza colaboradores (2017), encontraron simulaciones adecuadas para los meses de menor precipitación y baja habilidad para los meses de mayor precipitación. El promedio de Región (línea gris oscuro) también subestima a CRU y el sesgo seco y la alta dispersión se reduce en gran medida por el modelo IPSL-CM6A-LR.

El modelo IPSL-CM6A-LR y CRU reproduce correctamente el ciclo medio anual de precipitación en la región del estudio con dos máximos de precipitación, característico de la región Centroamericana, además

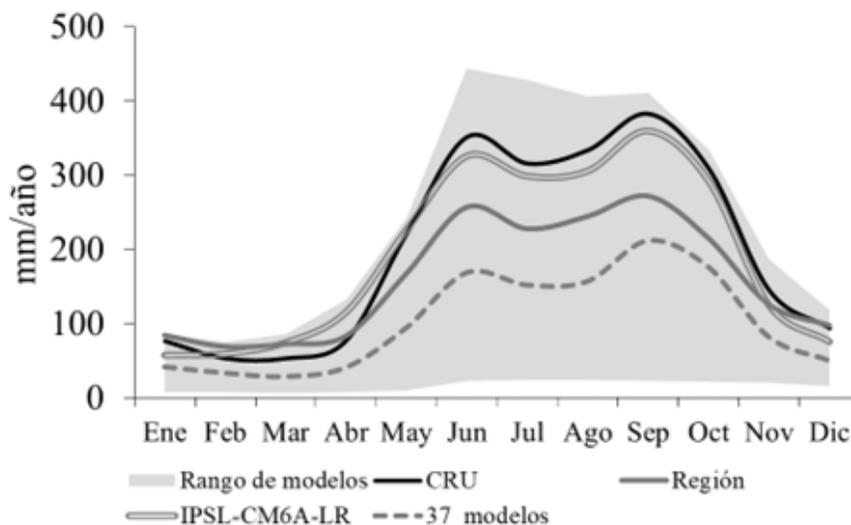
de la Sequía de Medio Verano (Canícula) la cual es adecuadamente simulada por los modelos en general.

Los gráficos de dispersión de precipitación mensual se pueden observar en la Figura 4, donde se compara la serie CRU en el eje X y en el eje Y el modelo IPSL-CM6A-LR (Figura 4A), Región (Figura 4B) y Promedio de 37 modelos (Figura 4C). Los círculos rellenos corresponden a los meses de poca precipitación mensual (Nov, Dic, Ene, Feb, Mar y Abr) en donde los modelos se ajustan bastante bien a las cantidades de lluvia, los meses de mayor precipitación en círculos sin relleno presentan una mayor dispersión en comparación con los meses de menor lluvia.

La regresión lineal del modelo IPSL-CM6A-LR presenta una pendiente ( $m$ ) = 0.71 y un coeficiente de determinación ( $R^2$ ) = .68 entendiéndose que la mejor pendiente 1:1 y sería de valor de 1 y el mejor  $R^2$  sería un valor de 1, el promedio de Región presenta una  $m$  = .49 y un  $R^2$  = .60 y el promedio de 37 modelos obtiene  $m$  = .39 y  $R^2$  = .74. En general, los modelos tienden a subestimar la precipitación media en los meses de lluvia y sobreestimar en meses con bajas precipitaciones, es decir subestimar las precipitaciones superiores a 400 mm y sobreestimar las precipitaciones por debajo de 20 mm. La dispersión de datos es menor para las precipitaciones bajas y aumenta para valores altos. Estos resultados sugieren que, si bien los GCM individuales son capaces de reconocer la variabilidad

**Figura 3**

*Ciclo anual (mm/mes) de la precipitación observada por CRU y simulada por los CIMIP6, Modelo IPSL-CM6A-LR y Región*



temporal de la serie, presentan dificultades para simular las cantidades de la lluvia mensual.

La gráfica de dispersión del conjunto de 37 modelos (Figura 4C) muestra bandas muy dispersas y un sesgo seco durante todo el año. Además, valores mensuales de baja precipitación (menores de 20 mm de lluvia) no son simulados por el ensemble. El modelo IPSL-CM6A-LR (Figura 4A) tiene un comportamiento similar a los datos observados CRU, pero subestima los meses de lluvia. En general, los modelos tienen bastante dispersión en los valores más altos de precipitación y menor dispersión en los valores bajos de precipitación. Estos resultados sugieren que, si bien los GCM individuales son capaces de reconocer la variabilidad temporal de la serie, presentan dificultades para simular las cantidades de la lluvia mensual. La Figura 4B muestra la dispersión entre los datos de Región y CRU, mostrando una menor dispersión los datos, pero con una subestimación en los valores de precipitación altos.

La Figura 5 muestra el rendimiento de los modelos en el Diagrama de Taylor. Los diagramas de Taylor resumen el grado de correspondencia entre los campos observados y simulados en términos de la relación de sus variaciones (Taylor, 2001). El grupo de los mejores modelos son los que más se acercan al origen CRU. Los valores de desviación estándar individuales indican valores similares entre trenes los modelos, pero el modelo IPSL-CM6-LR (punto gris con número 1)

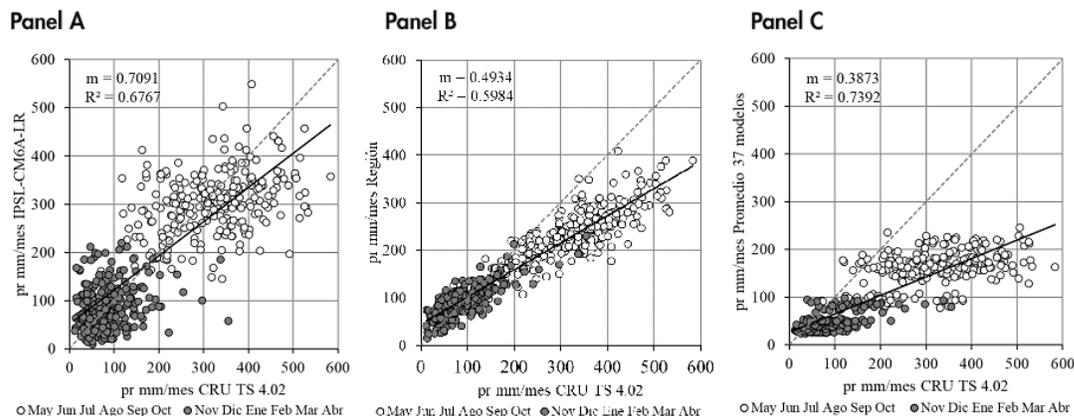
se acercan más a CRU (punto negro), además de cuentan con correlaciones superiores a .65. Los números corresponden al ranquin de la Tabla 2. El punto con número 1 corresponden al modelo IPSL-CM6A-LR y R corresponde a Región.

### Simulación histórica de temperatura mensual, 43 años (1971-2014)

Las métricas de evaluación de los modelos CMIP6 de las simulaciones históricas del periodo 1971 a 2014 se muestran en el ranquin de la Tabla 3, en general todos los modelos indican que la temperatura media de la región seleccionada está bien simulada. Los modelos tienen correlaciones en un promedio de 0.8 y errores relativamente altos con un promedio de RMSE 1.4 °C, los valores de los errores MAE están en un promedio de 1.2 °C. El RMSE de los primeros 10 modelos está en un rango de 0.8 a 1 °C y un MAE de entre 0.6 a 0.8, los valores negativos de MBE muestran que los modelos son más bajos que los observado por CRU. Los modelos en general presentan una eficiencia NSE aceptables, las cuales son satisfactorias según lo recomendado por Moriasi y colaboradores (2007). Los 10 primeros modelos lograron las mejores métricas de evaluación, pero no en gran medida. El modelo CIESM presenta las mejores métricas con CCP y CCS de 0.85,

**Figura 4**

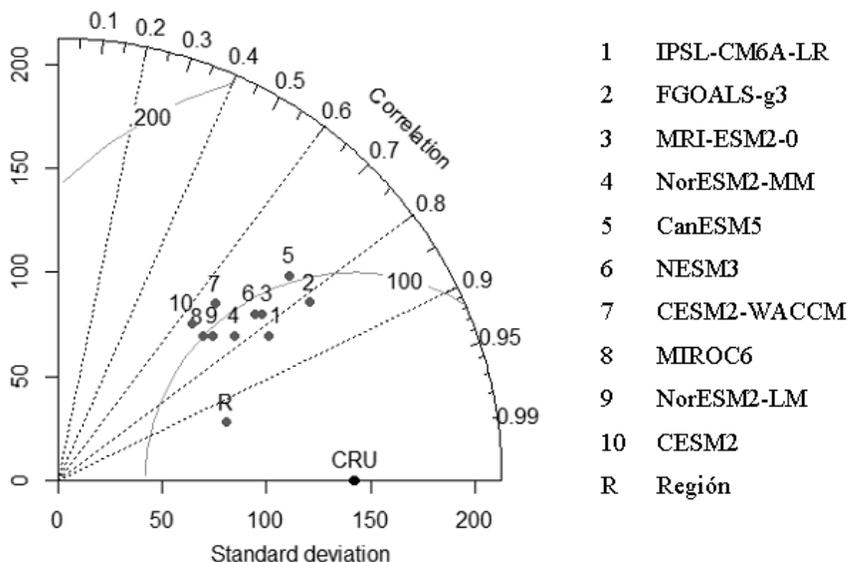
*Gráficos de dispersión de precipitación mensual simulada versus observada*



*Nota.* Panel A modelo IPSL-CM6A-LR; Panel B Región y Panel C Promedio de 37. La línea de regresión lineal se traza y su pendiente “m” se presenta juntas con el coeficiente de determinación  $R^2$  en la esquina superior izquierda.

**Figura 5**

*Gráficos de dispersión de precipitación mensual simulada versus observada*



*Nota.* El punto negro corresponde a CRU, los puntos grises son los 10 mejores modelos, la numeración corresponde al ordenamiento de la Tabla 2. La curva centrada en CRU corresponde a CRMS: raíz de error medio cuadrático centrado y “R” al promedio Región de 66 estaciones locales.

NSE 0.65, RMSE 1.38 °C, MBE -0.03 °C y MAE 1.15 °C. En el caso de los datos de Región se puede mencionar que su correlación con los datos CRU es bajo.

La Figura 6 presenta la serie temporal de temperatura media anual para el modelo con mejores métricas CIESM (línea gris clara), CRU (línea negra), el promedio Región (línea gris oscura) y los modelos CMIP6 en rango de modelos (área gris) y su promedio en línea gris discontinua. El rango de los 37 modelos (área gris) presenta una gran amplitud y su promedio se ajusta la tendencia de a CRU. El promedio de Región queda por debajo de CRU y el mejor modelo CIESM se asemeja bastante a los datos de CRU (KGE = 0.77, NSE = 0.65 y CCP = 0.87). Todos los modelos presentan una tendencia muy similar a los datos CRU.

La climatología observada por CRU (línea negra) y los simulados por modelos, se puede ver en la Figura 7 donde se presenta el ciclo anual de temperatura. El promedio de 37 modelos (área gris) presenta una amplia amplitud y su promedio (línea discontinua) y

el modelo CIEM (línea gris clara) se ajustan muy bien a CRU. El promedio de Región (línea gris oscuro) queda por debajo de CRU en los meses de enero a agosto y se ajusta bien solamente en los meses fríos de septiembre a diciembre. El promedio de modelos reproduce bien en los meses de octubre, noviembre y diciembre, correspondiente a la transición de otoño a invierno boreal. Estos resultados sugieren que no todos los modelos logran simular correctamente el ciclo anual medio de temperatura observada.

Los gráficos de dispersión de la temperatura simulada por los modelos y CRU se presentan en Figura 8 para el modelo CIESM, Figura 8A para el promedio de Región, Figura 8B y para el promedio de los 37 modelos en la Figura 8C. La lineal línea de regresión de modelo CIESM presenta un  $R^2 = .75$  y  $m = 1.04$ , Región con  $R^2 = .5$  y  $m = .5$  y el promedio de 37 modelos presenta un buen ajuste con  $R^2 = .87$  y  $m = 1$ . La dispersión de los datos es similar en los meses fríos que en los meses cálidos.

**Tabla 3**

*Métricas de comparación estadística entre las series temporales de temperatura mensual observada por CRU, simulaciones CMIP6 y promedio de estaciones locales "Región", para el periodo (1971-2014). Ranking, Modelo, Distancia, KGE, NSE, CCP, CCS, RMSE, DS (°C/mes), MAE y MBE en (°C/mes)*

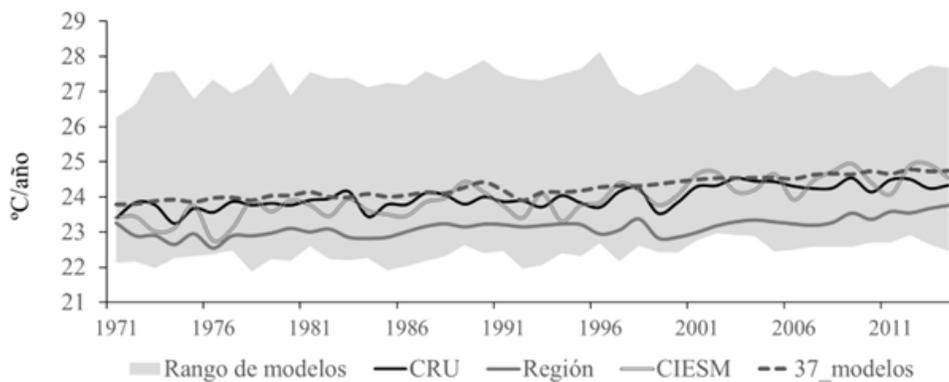
Modelos CMIP6, CRU y Región	Distancia	KGE	NSE	CCP	CCS	RMSE	DS	MAE	MBE
CRU	0.00	1	1	1	1	0	1.41	0	0
1 CIESM	0.88	0.77	0.65	0.87	0.87	0.83	1.68	0.65	-0.03
2 CESM2-WACCM	0.90	0.82	0.61	0.83	0.81	0.88	1.49	0.72	0.25
3 MRI-ESM2-0	0.93	0.78	0.61	0.86	0.86	0.88	1.66	0.68	-0.25
4 CanESM5	1.01	0.81	0.52	0.85	0.86	0.98	1.57	0.76	0.50
5 FGOALS-g3	1.02	0.76	0.52	0.83	0.83	0.98	1.65	0.72	-0.36
6 MPI-ESM1-2-HR	1.04	0.73	0.51	0.81	0.81	0.99	1.69	0.81	-0.13
7 NorCPM1	1.05	0.79	0.48	0.87	0.85	1.02	1.65	0.84	0.62
8 CESM2	1.07	0.81	0.45	0.83	0.82	1.05	1.54	0.87	0.59
9 E3ESM-1-0	1.08	0.69	0.51	0.84	0.82	0.99	1.79	0.78	0.14
10 NorESM2-MM	1.08	0.81	0.43	0.82	0.78	1.06	1.49	0.85	-0.60
11 FIO-ESM-2-0	1.10	0.75	0.44	0.84	0.83	1.06	1.68	0.81	-0.55
12 FGOALS-f3-L	1.11	0.79	0.41	0.84	0.81	1.08	1.60	0.84	-0.65
13 MPI-ESM1-2-LR	1.12	0.71	0.43	0.77	0.77	1.07	1.66	0.84	-0.04
14 GISS-E2-1-G	1.16	0.64	0.45	0.83	0.81	1.05	1.86	0.84	-0.09
15 EC-Earth3	1.18	0.69	0.38	0.82	0.83	1.12	1.76	0.89	-0.47
16 EC-Earth3-Veg	1.19	0.67	0.39	0.83	0.83	1.10	1.82	0.90	-0.42
17 IPSL-CM6A-LR	1.20	0.69	0.35	0.79	0.79	1.14	1.09	0.96	-0.75
18 AWI-CM-1-1-MR	1.21	0.70	0.31	0.73	0.72	1.17	1.59	0.95	0.37
19 MPI-ESM1-2-HAM	1.22	0.67	0.31	0.67	0.64	1.17	1.34	0.93	-0.36
20 E3Sm-1-1	1.22	0.62	0.38	0.85	0.83	1.11	1.90	0.91	0.46
21 GISS-E2-1-G-CC	1.25	0.56	0.40	0.85	0.83	1.09	2.00	0.88	-0.07
22 BCC-CSM2-MR	1.29	0.68	0.25	0.84	0.83	1.22	1.80	1.03	0.73
23 SAM0-UNICON	1.37	0.67	0.15	0.81	0.77	1.30	1.80	1.02	-0.76
24 NorESM2-LM	1.40	0.74	0.06	0.82	0.81	1.37	1.67	1.15	0.97
25 ACCESS-CM2	1.48	0.68	0.00	0.87	0.85	1.41	1.83	1.16	-1.07
26 KACE-1-0-G	1.58	0.76	-0.21	0.81	0.81	1.56	1.62	1.31	1.24
27 GFDL-ESM4	1.58	0.54	-0.05	0.89	0.88	1.45	2.04	1.16	-1.02
28 CESM2-FV2	1.63	0.65	-0.23	0.77	0.76	1.57	1.79	1.34	1.08
29 CAMS-CSM1-0	1.66	0.71	-0.31	0.86	0.83	1.62	1.77	1.37	-1.35
30 NESM3	1.71	0.64	-0.35	0.86	0.87	1.64	1.87	1.45	-1.32
31 MCM-UA-1-0	1.73	0.68	-0.42	0.82	0.80	1.68	1.79	1.42	1.34
32 INM-CM4-8	2.15	0.26	-0.80	0.83	0.81	1.89	2.43	1.45	1.17

**Tabla 3 (continuación)**

Modelos CMIP6, CRU y Región	Distancia	KGE	NSE	CCP	CCS	RMSE	DS	MAE	MBE
33 INM-CM5-0	2.27	0.24	-1.03	0.82	0.80	2.01	2.46	1.59	1.31
34 BCC-ESM1	2.32	0.83	-1.68	0.85	0.86	2.31	1.42	2.18	2.18
35 CESM2-WACCM-FV2	2.33	0.61	-1.60	0.83	0.81	2.28	1.90	2.04	2.00
36 MIROC6	2.44	0.47	-1.79	0.60	0.61	2.36	1.89	1.91	1.79
37 GISS-E2-1-H	3.50	0.75	-5.12	0.80	0.80	3.49	1.53	3.37	3.37
Región	1.88	0.04	-0.17	0.20	0.20	1.53	0.67	1.33	-0.53

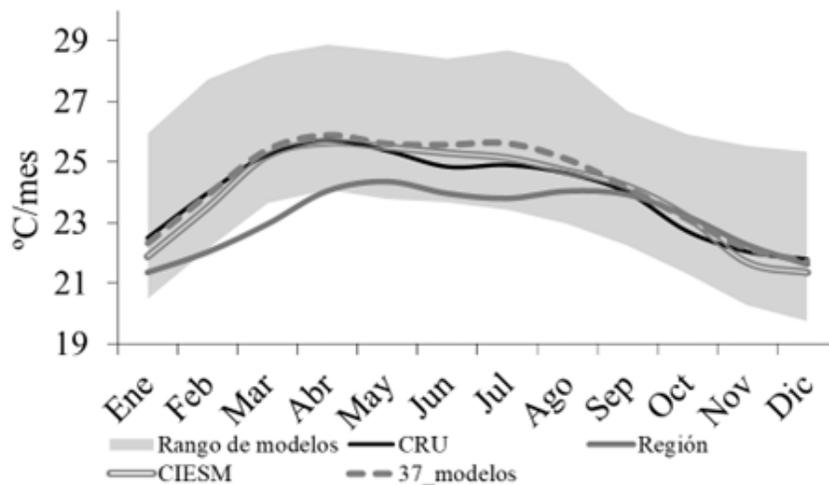
**Figura 6**

Serie anual de temperatura anual (°C/año) observada por CRU y simulada por los CIMIP6, modelo CIESM y Región



**Figura 7**

Serie anual de temperatura anual (°C/año) observada por CRU y simulada por los CIMIP6, modelo CIESM y Región



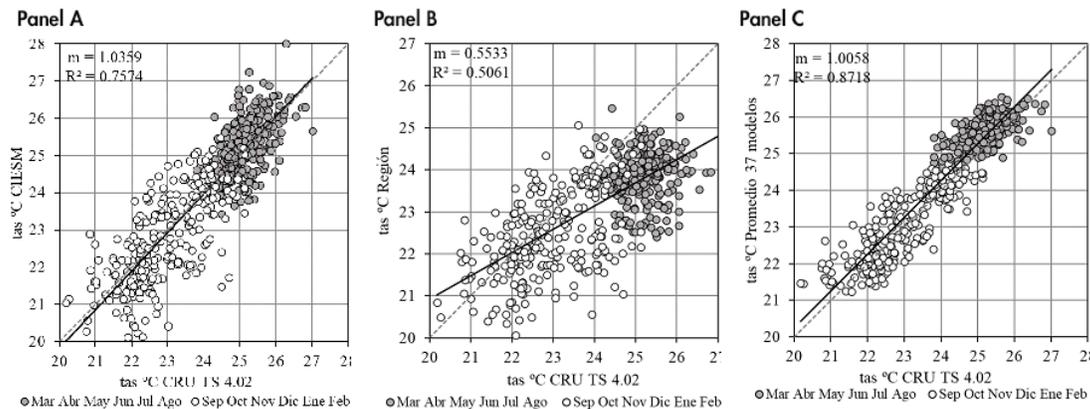
La Figura 9 muestra el diagrama Taylor de temperatura de la región seleccionada para los 10 mejores modelos y el promedio de Región (Datos de 66 estaciones locales). El punto negro de referencia CRU muestra que las observaciones tienen una desviación estándar de 1.4 °C. En general el diagrama muestra que los modelos representan correctamente la desviación estándar de referencia. Los modelos se presentan en el orden del ranking de la Tabla 3. Los coeficientes de correlación son superiores a 0.8. Además, los 5 modelos presentan correlaciones similares, sus desviaciones es-

tándar están entre los 1.06 a 1.85 y RMSE menores a 1. En términos generales, la gráfica de Taylor es consistente con el ordenamiento del ranking de modelos en base a la distancia de las métricas DS, C.C. Pearson y RMSE.

El punto negro corresponde a CRU, los puntos grises son los 10 mejores modelos, la numeración corresponde al ordenamiento de la Tabla 2. La curva centrada en CRU corresponde a CRMS: raíz de error medio cuadrático centrado y R al promedio Región de 66 estaciones locales.

**Figura 8**

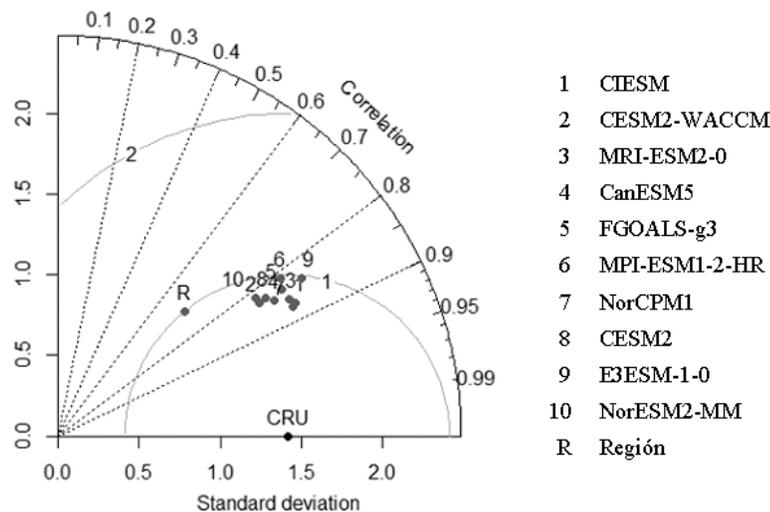
*Serie anual de temperatura anual (°C/año) observada por CRU y simulada por los CIMIP6, modelo CIESM y Región*



*Nota.* Panel A modelo CIESM; Panel B Región y Panel C Promedio de 37 modelos. La línea de regresión lineal se traza y su pendiente “m” se presenta juntas con el coeficiente de determinación R<sup>2</sup> en la esquina superior izquierda.

**Figura 9**

*Diagrama de Taylor de las simulaciones de temperatura (periodo 1971-2014)*



Los modelos que replican adecuadamente ambas variables del periodo comparado se presentan en la Tabla 4.

**Tabla 4**

*Ranking final de GCMs considerando su habilidad para reproducir temperatura y precipitación mensual del periodo de 1971 a 2014 de CRU*

GCMs para Precipitación		GCMs para Temperatura	
1	IPSL-CM6A-LR	1	CIESM
2	FGOALS-g3	2	CESM2-WACCM
3	MRI-ESM2-0	3	MRI-ESM2-0
4	NorESM2-MM	4	CanESM5
5	CanESM5	5	FGOALS-g3
6	NESM3	6	MPI-ESM1-2-HR
7	CESM2-WACCM	7	NorCPM1
8	MIROC6	8	CESM2
9	NorESM2-LM	9	E3ESM-1-0
10	CESM2	10	NorESM2-MM

En la Tabla 4 se puede notar que los modelos FGOALS-g3, MRI-ESM2-0, NorESM2-MM, CESM2-WACCM, CESM2 (con sus números sombreados) están entre los primeros 10 modelos en ambas variables, por lo que los ajustes que se le realicen a estos modelos utilizando una reducción de escala estadística o dinámica deberían ser menores que los de los demás modelos para simulaciones históricas del clima de la región en estudio. También se puede observar que los modelos IPSL-CM6A-LR y CIESM son los mejores para cada variable, precipitación y temperatura respectivamente.

## Discusión

Este documento evaluó la capacidad de los GCMs CMIP6 para simular el comportamiento espacio temporal observado en la región de estudio. Los GCMs fueron seleccionados de dos grupos de simulaciones CMIP6, para el periodo de 1971 a 2014. Las simulaciones mensuales de precipitación y temperatura fueron evaluadas con el grupo de datos CRU TS 4.02 observado. Las simulaciones de cada GCM y los grupos

multi-modelo fueron evaluados a través del MBE, el MAE, el RMSE, los coeficientes NSE, KAGE y las correlaciones de Pearson y Spearman. Estas métricas fueron calculadas para las series temporales con el promedio del área de la región de estudio. Los resultados permitieron seleccionar un subgrupo de modelos que representan mejor la precipitación y temperatura mensual en el periodo seleccionado.

Para la precipitación los coeficientes de correlación oscilan entre 0,34 a 0,81 respecto a CRU. En esa misma línea Choy y colaboradores (2022), encontraron para el Sur de África que los coeficientes de correlación tienden a estar entre 0.4 a 0.90 los cuales van a variar según la ubicación geográfica y la dinámica atmosférica de la región estudiada. El RMSE tienden a ser bastante uniformes entre modelos y varían entre 86 a 219 mm. Estos errores son altos en comparación con otras regiones de Suramérica (Gulizia & Camilloni, 2015) y en Lovino et al., 2018. Pero hay que tomar en cuenta que son regiones climáticas distintas a las de este estudio.

El coeficiente de correlación es más útil como medida de la fase entre series de tiempo, y los errores se pueden corregir utilizando estadísticas métodos (por ejemplo, reducción de escala). Los 10 modelos escogidos como mejores en base a la menor distancia en el diagrama en 3 dimensiones (Desv, RMSE y Cor Pearson) tuvieron correlaciones superiores a 0.75 se eligieron para realizar un promedio, lo modelos son los sombreados en la Tabla 4. Las puntuaciones estadísticas en estos 10 modelos son mejores que el resto de las modelos, los errores se reducen y aumenta la eficiencia.

Las observaciones de temperatura y las simulaciones muestran que la región tiene una tendencia de calentamiento en la temperatura media anual en los últimos 10 años. Las observaciones de CRU y las simulaciones de los GCMs, presentan un aumento en el ciclo anual de temperatura de aproximadamente de 0.5 °C. Los mejores 10 modelos alcanzan correlaciones en superiores a 0.8 respecto a CRU. Los modelos CIESM, CESM2-WACCM, MRI-ESM2-0, CanESM5 y FGOALS-g3 presentan buenos valores en las métricas de evaluación para la habilidad de simular la temperatura regional de CRU.

Las observaciones de precipitación de CRU de 1971-2014 muestran que la región tiene una marcada variabilidad interanual, la cual es difícil de simular por los GCMs. Para el caso del ciclo anual los modelos de CMIP6 simulan adecuadamente los dos máximos de precipitación anual y la sequía de medio verano de la región (Canícula), pero en general presentan una

cuantificación menor a CRU en promedio de casi un 50% de precipitación media anual.

Para precipitación el modelo IPSL-CM6A-LR muestra un mejor ajuste que los demás, reduciendo los sesgos y subestimando solo un 4% de la precipitación media anual de CRU. El promedio de todos los modelos subestima a CRU en un 48% y en la serie interanual este conjunto no identifica la precipitación máxima que existieron en algunos años en particular como en el 1998 cuando ocurrió el huracán Mitch, el 2005 cuando ocurrió el huracán Stan y más evidentemente en el 2010 cuando se produjo la tormenta tropical Agatha en la que produjo una precipitación media anual de superior a los 2,200 mm y los modelos subestimaron en casi 300 mm anuales. La mayoría de los MCG tienden a subestimar la precipitación según se observa en la métrica MBE, por lo tanto, los errores estadísticos de precipitación son altos, lo que resulta en bajas eficiencias de Nash-Sutcliffe.

La evaluación de las simulaciones permitió seleccionar un subconjunto de 10 modelos (IPSL-CM6A-LR, FGOALS-g3, MRI-ESM2-0, NorESM2-MM, CanESM5, NESM3, CESM2-WACCM, MIROC6, NorESM2-LM yCESM2) que mejor se reproducen los campos de precipitación y un subconjunto de 10 modelos (CIESM, CESM2-WACCM, MRI-ESM2-0, CanESM5, FGOALS-g3, MPI-ESM1-2-HR, NorCPM1, CESM2, E3ESM-1-0 y NorESM2-MM) que más hábilmente representa la temperatura media regional. Se espera que estos modelos que representan satisfactoriamente el clima histórico sean los más apropiado para simular el clima futuro. Aunque se reconoce que es necesario investigar otras señales climáticas detectadas los modelos de la Fase 6 del Proyecto de Intercomparación de Modelos Acoplados (CMIP6); como por ejemplo el fenómeno ENOS, para comprender aún más la habilidad de estos (Zhao & Sun, 2022).

### Agradecimientos

Se agradece a los revisores anónimos por sus valiosos comentarios y observaciones. Se agradece al profesor Dr. Miguel Lovino por el asesoramiento de este artículo. Se agradece a Earth System Grid Federation (ESGF) por proporcionar acceso al conjunto de datos CMIP6. Se agradece al Servicio Meteorológico de Belice, a la Comisión Nacional del Agua (Conagua) de México, al Instituto Sismológico, Vulcanológico, Meteorológico e Hidrológico (Insivumeh) de Guatemala y al portal de datos de Centro Clima de

Cómitre de Regional de Recurso Hidráulicos (CRRH) de Centroamérica por los datos de estaciones locales obtenidos.

### Contribución de los autores

Coordinación, elaboración y revisión del Documento: todos los autores; P Rivera, E Herrera, W Ochoa.

Diseño de la recolección de datos o del trabajo en campo: P Rivera.

Recolección o contribución de datos o realización del trabajo de campo: P Rivera, E Herrera.

Limpieza, sistematización, análisis o visualización de datos: todos los autores. P Rivera, E Herrera, W Ochoa.

Participación en análisis de datos, estructura y en la escritura del documento: todos los autores. P Rivera, E Herrera, W Ochoa.

### Materiales suplementarios

Este artículo no tiene archivos complementarios.

### Referencias

- Agyekum, J., Annor, T., Quansah, E., Lamptey, B., & Okafor, G. (2022). Extreme precipitation indices over the Volta Basin: CMIP6 model evaluation. *Scientific African*, *16*, Artículo e01181. <https://doi.org/10.1016/j.sciaf.2022.e01181>
- Almazroui, M., Islam, M. N., Saeed, F., Saeed, S., Ismail, M., Ehsan, M. A., Diallo, I., O'Brien, E., Ashfaq, M., Martínez-Castro, D., Cavazos, T., Cerezo-Mota, R., Tippett, M. K., Gutowski, W. J., Alfaro, E. J., Hidalgo, H. G., Vichot-Llano, A., Campbell, J. D., Kamil, S., ... Barlow, M. (2021). Projected Changes in Temperature and Precipitation Over the United States, Central America, and the Caribbean in CMIP6 GCMs. *Earth Systems and Environment*, *5*(1), 1-24. <https://doi.org/10.1007/s41748-021-00199-5>
- Ayugi, B., Zhihong, J., Zhu, H., Ngoma, H., Babausmail, H., Rizwan, K., & Dike, V. (2021). Comparison of CMIP6 and CMIP5 models in simulating mean and extreme precipitation over East Africa. *International Journal of*

- Climatology*, 41(15), 6474-6496. <https://doi.org/10.1002/joc.7207>
- Lim Kan Sian, K. T. C., Hagan, D. F. T., Ayugi, B. O., Nooni, I. K., Ullah, W., Babaousmail, H., & Ongoma, V. (2022). Projections of Precipitation Extremes based on Bias-corrected CMIP6 Models Ensemble over Southern Africa. *International Journal of Climatology*. Publicación anticipada en línea. <https://doi.org/10.1002/joc.7707>
- Doty, B., & Kinter, III, J. L. (1995). *Geophysical data analysis and visualization using the grid analysis and display system.*, En E. P. Szuszcwicz & J.H. Bredekamp (Eds.), *Visualization Techniques in Space and Atmospheric Sciences* (pp. 209-219). NASA.
- Fasullo, J. T., Phillips, A. S., & Deser, C. (2020). Evaluation of Leading Modes of Climate Variability in the CMIP Archives. *Journal of Climate*, 33(13), 5527-5545. <https://doi.org/10.1175/jcli-d-19-1024.1>
- Gulizia, C., & Camilloni, I. (2015). Comparative analysis of the ability of a set of CMIP3 and CMIP5 global climate models to represent precipitation in South America. *International Journal of Climatology*, 35(4), 583-595. <https://doi.org/10.1002/joc.4005>
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1-2), 80-91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Harris, I., Osborn, T. J., Jones, P., & Lister, D. (2020). Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. *Scientific Data*, 7, Artículo 109. <https://doi.org/10.1038/s41597-020-0453-3>
- Kim, Y. H., Min, S. K., Zhang, X., Sillmann, J., & Sandstad, M. (2020). Evaluation of the CMIP6 multi-model ensemble for climate extreme indices. *Weather and Climate Extremes*, 29, Artículo 100269. <https://doi.org/10.1016/j.wace.2020.100269>
- Lee, T., Waliser, D. E., Li, J. L. F., Landerer, F. W., & Gierach, M. M. (2013). Evaluation of CMIP3 and CMIP5 wind stress climatology using satellite measurements and atmospheric reanalysis products. *Journal of Climate*, 26(16), 5810-5826. <https://doi.org/10.1175/JCLI-D-12-00591.1>
- Lovino, M. A., Müller, O. V., Berbery, E. H., & Müller, G. V. (2018). Evaluation of CMIP5 retrospective simulations of temperature and precipitation in northeastern Argentina. *International Journal of Climatology*, 38(S1), Artículo e1158-e1175. <https://doi.org/10.1002/joc.5441>
- Lu, Z., Zhao, T., & Zhou, W. (2020). Evaluation of the Antarctic Circumpolar Wave Simulated by CMIP5 and CMIP6 Models. *Atmosphere*, 11(9), Artículo 931. <https://doi.org/10.3390/atmos11090931>
- Lupo, A., & Kininmonth, W. (2013). Global Climate Models and Their Limitations. En C. D Idso, R. M. Carter & S. F. Singer (Eds.), *Climate Change Reconsidered II, Physical Science* (pp. 7-148). Global Climate Models and Their Limitations. *Climate Change Reconsidered II*.
- Maenza, R. A., Agosta, E. A., & Bettolli, M. L. (2017). Climate change and precipitation variability over the western 'Pampas' in Argentina. *International Journal of Climatology*, 37(S1), 445-463. <https://doi.org/10.1002/joc.5014>
- Meher, J. K., Das, L., Akhter, J., Benestad, R. E., & Mezghani, A. (2017). Performance of CMIP3 and CMIP5 GCMs to simulate observed rainfall characteristics over the western Himalayan region. *Journal of Climate*, 30(19), 7777-7799. <https://doi.org/10.1175/JCLI-D-16-0774.1>
- Moriasi, D., Arnold, J., Van\_Liew, M., Bingner, R., Harmel, R., & Veith, T. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *American Society of Agricultural and Biological Engineers*, 50(1), 885-900. <https://doi.org/10.1234/590>
- Nash, J. E., & Sutcliffe, J. V. (1970). River Flow Forecasting Through Conceptual Models Part 1-A Discussion of Principles. *Journal of Hydrology*, 10(3), 282-290. <https://doi.org/10.1080/00750770109555783>
- Panel Intergubernamental del Cambio Climático (Ed.). (2014). *Anexo II: Glosario. Cambio Climático 2014: Informe de Síntesis. Contribución de Los Grupos de Trabajo I, II y III Al Quinto Informe*

- de Evaluación Del Grupo Intergubernamental de Expertos Sobre El Cambio Climático.*
- Palomino-Lemus, R., Córdoba-Machado, S., & Esteban-Parra, M. J. (2015). Evaluación de modelos climáticos globales del CMIP5 sobre el noroeste de América del Sur. *Revista Biodiversidad Neotropical*, 5(1), 16-22.
- Penalba, O. C., & Rivera, J. A. (2016). Regional aspects of future precipitation and meteorological drought characteristics over Southern South America projected by a CMIP5 multi-model ensemble. *International Journal of Climatology*, 36(2), 974-986. <https://doi.org/10.1002/joc.4398>
- Rogelis, M. C., Werner, M., Obregón, N., & Wright, N. (2016). Hydrological model assessment for flood early warning in a tropical high mountain basin. *Hydrology and Earth System Sciences Discussions*, March, 1-36. <https://doi.org/10.5194/hess-2016-30>
- Roussel, M.-L., Lemonnier, F., Genthon, C., & Krinner, G. (2020). Brief communication: Evaluating Antarctic precipitation in ERA5 and CMIP6 against CloudSat observations. *The Cryosphere Discussions*, 14(8), 2715-2727. <https://doi.org/10.5194/tc-2019-327>
- Sheffield, J., Camargo, S. J., Fu, R., Hu, Q., Jiang, X., Johnson, N., Karnauskas, K. B., Kim, S. T., Kinter, J., Kumar, S., Langenbrunner, B., Maloney, E., Mariotti, A., Meyerson, J. E., Neelin, J. D., Nigam, S., Pan, Z., Ruiz-Barradas, A., Seager, R., ... Zhao, M. (2013). North American climate in CMIP5 experiments. Part II: Evaluation of historical simulations of intraseasonal to decadal variability. *Journal of Climate*, 26(23), 9247-9290. <https://doi.org/10.1175/JCLI-D-12-00593.1>
- Shu, Q., Wang, Q., Song, Z., Qiao, F., Zhao, J., Chu, M., & Li, X. (2020). Assessment of Sea Ice Extent in CMIP6 With Comparison to Observations and CMIP5. *Geophysical Research Letters*, 47(9), Artículo e2020GL087965. <https://doi.org/10.1029/2020GL087965>
- Sillmann, J., Kharin, V. V., Zhang, X., Zwiers, F. W., & Bronaugh, D. (2013). Climate extremes indices in the CMIP5 multimodel ensemble: Part I. Model evaluation in the present climate. *Journal of Geophysical Research Atmospheres*, 118(4), 1716-1733. <https://doi.org/10.1002/jgrd.50203>
- Taylor, K. E., Balaji, V., Hankin, S., Juckes, M., Lawrence, B., & Pascoe, S. (2012). CMIP5 Data Reference Syntax (DRS) and Controlled Vocabularies. [https://www.earthsystemcog.org/site\\_media/projects/wip/CMIP6\\_global\\_attributes\\_filenames\\_CVs\\_v6.2.6.pdf](https://www.earthsystemcog.org/site_media/projects/wip/CMIP6_global_attributes_filenames_CVs_v6.2.6.pdf)
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a Single Diagram. *Journal of Geophysical Research Atmospheres*, 106(D7), 7183-7192. <https://doi.org/10.1029/2000JD900719>
- Voltaire, A., Saint-Martin, D., Sénési, S., Decharme, B., Alias, A., Chevallier, M., Colin, J., Guérémy, J. F., Michou, M., Moine, M. P., Nabat, P., Roehrig, R., Salas y Méliá, D., Sférian, R., Valcke, S., Beau, I., Belamari, S., Berthet, S., Cassou, C., ... Waldman, R. (2019). Evaluation of CMIP6 DECK Experiments With CNRM-CM6-1. *Journal of Advances in Modeling Earth Systems*, 11(7), 2177-2213. <https://doi.org/10.1029/2019MS001683>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. <https://doi.org/10.3354/cr030079>
- Zhao, Y., & Sun, D.-Z. (2022). ENSO Asymmetry in CMIP6 Models. *Journal of Climate*, 35(17), 5555-5572. <https://doi.org/10.1175/JCLI-D-21-0835.1>