

EVALUACIÓN DEL DESEMPEÑO DE MODELOS DINÁMICOS Y ESTADÍSTICOS EN EL PRONÓSTICO DE PRECIPITACIONES ESTACIONALES EN AMÉRICA DEL SUR DURANTE EL OTOÑO.

Diego García Picasso¹, Candela Sol Glatstein¹, Marisol Osman^{1,2}
diegogarciapicasso@gmail.com

¹Departamento de Ciencias de la Atmósfera y los Océanos (FCEyN, UBA)

²Centro de Investigaciones del Mar y la Atmósfera (CIMA)

Palabras clave: predictibilidad, modelos climáticos, calibración

1. Introducción

En las últimas décadas, el acceso a pronósticos dinámicos históricos y observaciones de calidad ha permitido evaluar modelos actuales de predicción climática y desarrollar herramientas regionales de pronóstico estacional en Sudamérica (Osman et al., 2016). Junto a los modelos dinámicos, los modelos empíricos, en particular el análisis de correlación canónica (CCA), continúan siendo de uso corriente, ya que permiten extraer patrones predictivos robustos (Barnston et al., 1992, Osman M et al., 2021). El objetivo de este trabajo es desarrollar y evaluar la predictibilidad de la precipitación para el trimestre marzo, abril y mayo (MAM) entre los años 1983-2020 en Sudamérica. Para esto, se utiliza el modelo CanCM4i y pronósticos estadísticos y se los evalúa objetivamente utilizando métricas determinísticas y probabilísticas.

2. Metodología

El modelo CanCM4i cuenta con 10 miembros de ensamble y pronósticos retrospectivos desde 1980 hasta 2020. Su resolución es de $\sim 2.8^\circ$ para la atmósfera y $\sim 1^\circ$ para el océano. El modelo se inicializa en febrero y pronostica el trimestre Marzo-Abril-Mayo (MAM). La predictibilidad se analiza mediante el análisis de la señal, el ruido y el cociente señal-vs-ruido; y calculando el coeficiente de correlación de anomalías (ACC) entre los miembros del ensamble (ACC teórico), (Lorenz, 1982). Como el modelo puede presentar errores sistemáticos (Coelho et al., 2018), se lo calibra a partir de ajustar su media y desvío a las correspondientes de las observaciones. Por otro lado, se usa la técnica de CCA para corregir estos pronósticos.

Por otro lado, se explora el desarrollo de modelos estadísticos para pronosticar la misma estación. Se consideran regresiones lineales múltiples (MLR) y CCA usando predictores como el índice Niño 3.4, la oscilación anular del sur (SAM) y el dipolo del Índico (DPI). Se emplean estrategias de validación cruzada (CV) y divisiones de entrenamiento/testeo (TT) para generar y evaluar los modelos considerando un período de desarrollo de los modelos independiente del período de verificación de estos modelos. El desempeño de los modelos se hace a partir de las métricas de verificación determinísticas como el error medio o BIAS, el error absoluto medio (MAE). Por otro lado, con estos modelos se construyen pronósticos probabilísticos para los terciles de la distribución climatológica que son evaluados con los índices de verificación probabilísticos Brier Skill Score (BSS), el Rank Probability Skill Score (RPSS), las curvas ROC y los diagramas de confiabilidad.

3. Resultados y discusión

El CanCM4i muestra alta señal y predictibilidad en el noreste de Brasil y sudeste de Sudamérica (SESA). La Fig. 1a muestra una alta señal en la cordillera patagónica, el norte de Sudamérica y el SESA. En la Fig. 1b se observa el ruido, con niveles altos en el norte de Sudamérica, SESA y en los Andes centrales y australes. Esta alta varianza sugiere que existen grandes diferencias entre los diferentes ensambles del modelo, lo que puede implicar que, finalmente, el ruido esté enmascarando la señal significativa. En la Fig. 1c se muestra la predictibilidad potencial, donde se aprecian altos valores en el norte de Sudamérica, con máximos en el noreste de Brasil y SESA.

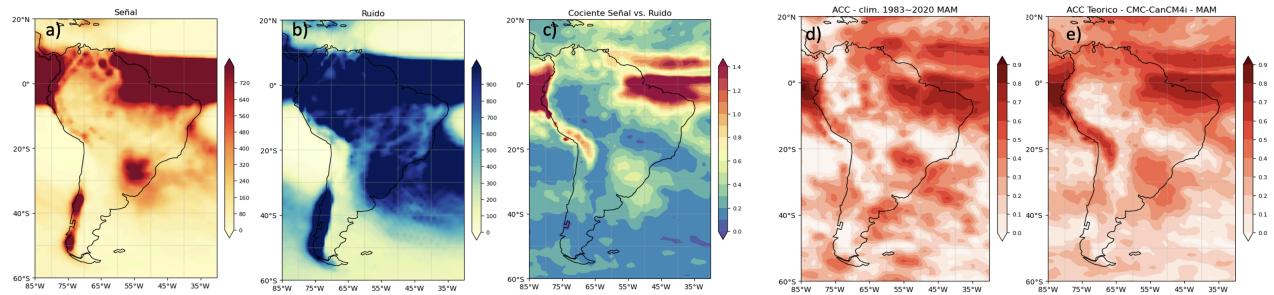


Figura 1. a-c) Métricas de la predictibilidad del modelo CanCM4i para trimestre MAM: a) señal (mm^2), b) ruido (mm^2), c) cociente señal versus ruido. d) ACC entre el CanCM4i y las observaciones (1983 y 2020) – MAM, (e) ACC teórico (modelo perfecto) del CanCM4i.

En varias regiones, como SESA y Patagonia oriental, la habilidad de predicción (Figura 1.d) supera al ACC teórico (Figura 1.e), lo que indica que el modelo subestima la predictibilidad real. En los Andes ocurre lo contrario: la predictibilidad teórica es alta, pero la habilidad baja. Esto sugiere exceso de confianza del modelo en sus propios resultados (conducen entre sí y no con las observaciones).

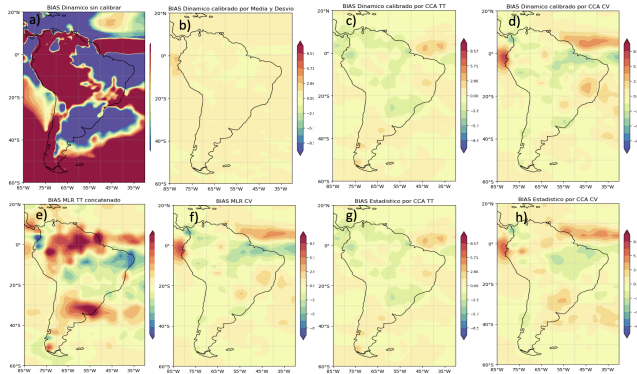


Figura 2. BIAS (mm) del modelo dinámico (a-d), modelo estadístico (e-f). Sin calibrar (a), calibrado por: media y desvío (b), CCA por TT (c), CCA CV (d), generado por: MLR con TT (e), MLR CV (f), CCA TT (g), CCA CV (h).

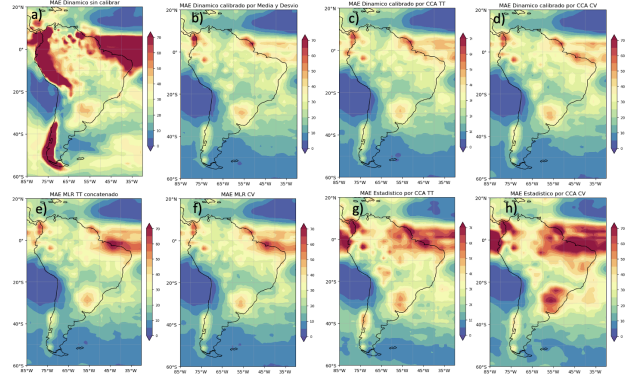


Figura 3. MAE (mm) del modelo dinámico (a-d), modelo estadístico (e-f). Sin calibrar (a), calibrado por: media y desvío (b), CCA por TT (c), CCA CV (d), generado por: MLR con TT (e), MLR CV (f), CCA TT (g), CCA CV (h)

Las Figuras 2 y 3 muestran que el modelo CanCM4i presenta un desempeño malo si no se lo calibra, ya que presenta un alto MAE (3a), pese a un BIAS bajo (2a). Al corregir el modelo ajustando su media y desvío climatológicos con las observaciones mejora notablemente el pronóstico, especialmente en regiones como SESA y el noreste de Brasil (2b y 3b). El modelo calibrado por CCA también muestra mejoras, aunque con sesgos regionales, subestimando o sobreestimando la precipitación según la zona (2c, 3c, 2d, 3d). Los modelos estadísticos, en particular el MLR TT (2e y 3e), tienen bajo rendimiento, mientras que el MLR CV mejora los resultados (2f y 3f).

Al desarrollar pronósticos probabilísticos, la calibración por media y desvío del modelo mejora los valores de BSS, RPSS y confiabilidad, con respecto al modelo sin calibrar.

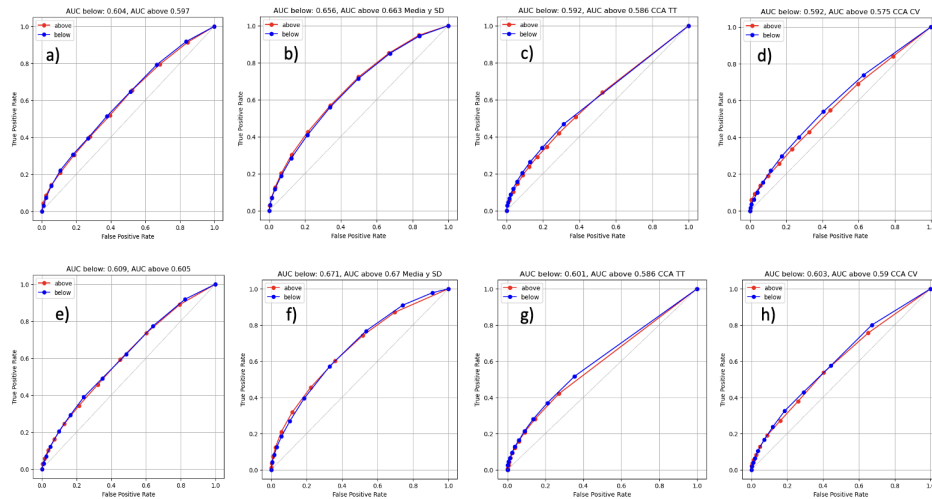


Figura 14. Curvas ROC para el modelo dinámico probabilístico por método de: conteo (a-d), ajuste gaussiano (c-d). Sin calibrar (a, e), calibrado por media y desvío (b, f), calibrado por CCA TT (c, g) y calibrado por CCA CV (d, h).

En la Fig. 4 el área bajo la curva ROC fue mayor para los pronósticos calibrados por media y desvío (0,67) en comparación con los otros modelos (0,60 para eventos secos y 0,55 para eventos húmedos). Este resultado corrobora una menor capacidad de discriminación para el modelo sin calibrar o calibrado por CCA, es decir, una menor resolución.

4. Conclusiones

La calibración mejora sustancialmente los pronósticos estacionales del modelo CanCM4i en Sudamérica, especialmente en regiones con alta predictibilidad como el noreste de Brasil y el SESA. El modelo sin calibrar muestra errores sistemáticos, corregibles con ajustes estadísticos. La calibración por media y desvío es efectiva y supera a la calibración vía CCA en varias regiones. El pronóstico probabilístico calibrado gana confiabilidad, aunque persisten desafíos en eventos extremos. Los modelos estadísticos, si bien menos precisos, aportan valor, en especial el MLR con validación cruzada. Finalmente, un enfoque multimodelo integrado podría combinar las fortalezas de ambos tipos de modelos, mejorando la predicción estacional para Sudamérica.

Bibliografía

- Barnston AG, Glantz MH, He Y (1992) Predictive skill of statistical and dynamical climate models in SST forecasting. *J Clim* 5: 631–648.
- Coelho C, Firpo M, Andrade F., 2018. A verification framework for South American sub-seasonal precipitation predictions. *Meteorologische Zeitschrift*, Vol. 27, No. 6, 503–520.
- Lorenz, E. N., 1982. Atmospheric predictability experiments with a large numerical model. *Tellus*, 34, 505–513.
- Osman M, Vera CS (2017) Climate predictability and prediction skill on seasonal time scales over South America from CHFP models. *Clim Dyn*.
- Osman M, Coelho C, Vera CS (2021) Calibration and combination of seasonal precipitation forecasts over South America using Ensemble Regression. *Clim Dyn*.