



EVALUACIÓN DE PREDICTORES PARA EL PRONÓSTICO CLIMÁTICO

CHRISTIAN W. BARRETO SCHULER

Estudio desarrollado en el marco del POI-2017

Subdirección de Predicción Climática
Dirección de Meteorología y Evaluación Ambiental Atmosférica
SENAMHI

DICIEMBRE 2017

Evaluación de predictores para el pronóstico climático

Barreto C.¹

¹ Subdirección de Predicción Climática
SENAMHI-Perú

I. INTRODUCCIÓN

La Subdirección de Predicción Climática (SPC) del SENAMHI-PERU realiza de manera operativa los pronósticos estacionales a nivel nacional de las variables precipitación, temperatura máxima y temperatura mínima. Para ello se consideran las salidas oficiales de los modelos climáticos disponibles por la NOAA, ECMWF, entre otros. Asimismo, se han desarrollado pronósticos climáticos probabilísticos considerando la capacidad predictiva y persistencia de los predictores en el tiempo; estos pronósticos son realizados empleando variables predictores como son temperatura superficial del mar, viento zonal y meridional, geopotencial, etc. El método empleado para el desarrollo de los modelos estadísticos de predicción es el Análisis de Correlación Canónica (CCA, por sus siglas en inglés), el cual es ampliamente usado a nivel global por sus bondades en la búsqueda de mejores correlaciones entre predictores y predictantes. El software Climate Predictability Tool (CPT) desarrollado por el International Research Institute for Climate and Society (IRI) de la Universidad de Columbia, permite construir modelos estadísticos para el pronóstico estacional bajo el uso de la técnica de CCA, así como otros usos de estadística avanzada, dicho software es usado por el SPC.

El presente estudio buscó reforzar las herramientas de pronóstico estacional, planteando la evaluación de nuevos predictores, ya sea proveniente de datos observados o de datos modelados, como de los North American Multi-model Ensemble (NMME). Para ello, se ha continuado con el empleo del software CPT, haciendo uso además de otras aplicaciones de análisis.

II. OBJETIVO

Evaluar la capacidad predictiva de variables provenientes de los NMME y del ERSSTv4 para la precipitación acumulada durante el periodo de verano (diciembre-enero-febrero) sobre el territorio nacional.

III. DATOS Y METODOLOGÍA

Para el presente reporte se han usado como predictores datos grillados de temperatura superficial del mar (TSM) provenientes del ERSSTv4; y datos de TSM y precipitación (PP) provenientes de los 7 modelos del NMME (CFSv2, CMC-1, CMC-2, GFDL, GFDL-FLOR, NASA, NCAR-CCSM4), incluyendo además el ensamble de estos (Kirtman et al. 2014). Estos datos se encuentran disponibles en:

<http://iridl.ldeo.columbia.edu/SOURCES/.Models/.NMME/>.

Tabla 1. Modelos activos de los NMME

Model	Hindcast Period	No. of Members	Arrangement of Members	Lead (month)	Model resolution (atmos)	Model resolution (ocean)	Reference
Active							
NCEP/CFSv2	1982-2010	24 (28)	4 members (0, 6, 12, 18z) every 5 th day	0-9	T126L64	MOM4L40 .25deg Eq	Saha et al (2010)
GFDL/CM2.1	1982-2010	10	All 1 st of the month 0Z	0-11	2x2.5degL24	MOM4L50 .3deg Eq	Delworth (2006)
GFDL/CM2.5 (FLOR)	1982-present	24	All 1 st of the month 0Z	0-11	C18L32 (50km)	MOM5 L50 0.30 deg Eq 1degPolar1.5	Vecchi et al (2014)
CMC1-CanCM3	1981-2010	10	All 1 st of the month 0Z	0-11	CanAM3 T63L31	CanOM4L40 .94deg Eq	Merryfield et al (2013)
CMC1-CanCM4	1981-2010	10	All 1 st of the month 0Z	0-11	CanAM4 T63L35	CanOM4L40 .94deg Eq	Merryfield et al (2013)
NCAR/CCSM4	1982-2010	10	All 1 st of the month 0Z	0-11	0.9x1.25degL26	POPL60 .25deg Eq	Kirtman et al. (in prep)
NASA/GEOS5	1981-2010	11	4 mems every 5 days; 7 mems on last day of last month	0-9	1x1.25 deg L72	MOM4L40 .25deg Eq	Vernieres et al (2012)

Fuente: Kirtman et al. 2014.

Por otro lado, los datos observados (predictantes) corresponden a la data grillada de precipitación PISCOv2 (Peruvian Interpolated data of the SENAMHI's Climatological and hydrological Observations versión 2). Cabe señalar que los datos PISCOv2 fueron divididos en 9 regiones a lo largo del país, para lo cual se consideró costa, sierra y selva, y su posición norte, centro o sur (Figura 1).

La técnica empleada fue Canonical Correlation Analysis (CCA, por sus siglas en ingles), y se empleó el software Climate Predictability Tool (CPT) para los cálculos necesarios (Barnston, 1994; Wilks, 2006).

La estación del año objetivo fue diciembre-enero-febrero (DEF). Para los datos de TSM provenientes del ERSSTv4, se consideró el mes de noviembre como predictor. Asimismo, para los datos de TSM y PP provenientes de los NMME, se consideró las salidas

estacionales para DEF con condiciones iniciales de noviembre. El periodo climático durante los cálculos fue 1982-2010.



Figura 1. Nueve regiones de estudio sobre Perú.

Para el desarrollo de este estudio se plantearon los siguientes 6 experimentos:

- Experimento 1: El predictor es la variable TSM, sobre la región del Trópico global (0°W - 360°W , 30°S - 30°N). Se evaluaron datos de los NMME y del ERSSTv4.
- Experimento 2: El predictor es la variable TSM, sobre la región del Pacífico tropical (120°E - 70°W , 15°S - 15°N). Se evaluaron datos de los NMME y del ERSSTv4.
- Experimento 3: El predictor es la variable TSM, sobre la región del Atlántico tropical Norte (80°W - 15°W , 6°N - 22°N). Se evaluaron datos de los NMME y del ERSSTv4.
- Experimento 4: El predictor es la variable PP, sobre la región del Trópico global (0°W - 360°W , 30°S - 30°N). Solo se evaluaron datos de los NMME.
- Experimento 5: El predictor es la variable PP, sobre la región del Pacífico tropical (120°E - 70°W , 15°S - 15°N). Solo se evaluaron datos de los NMME.
- Experimento 6: El predictor es la variable PP, sobre la región del Atlántico tropical Norte (80°W - 15°W , 6°N - 22°N). Solo se evaluaron datos de los NMME.

El análisis del performance de los diferentes experimentos para la predicción de la precipitación acumulada promedio para el verano se dividió en dos etapas. La primera asociada al pronóstico determinístico, para lo cual se analizó la **correlación de Pearson (PC)** entre las observaciones y las predicciones en cada punto de grilla. El segundo enfoque, fue sobre el pronóstico probabilístico, para ello se cuantificó el indicador **Two Alternate Forced Choice Score for forecast categories (2AFC)**, por sus siglas en inglés). Los valores de 2AFC tienen un rango de 0 a 100 por ciento. Si el valor de 2AFC es mayor a 50, significa que el pronóstico es capaz de discriminar y es mejor que adivinar al azar; asimismo, valores de 50 indican que los pronósticos no son mejores que un pronóstico realizado usando meramente la climatología (Mason y Weigel, 2009). A modo de facilitar la discusión de este índice, para su análisis, se restó el valor de 50 a todos los scores de 2AFC obtenidos. Finalmente, ambos scores, PC y 2AFC, fueron analizados en forma de promedio sobre cada región correspondiente.

IV. RESULTADOS Y DISCUSIONES PRELIMINARES

4.1. PERFORMANCE DEL PRONÓSTICO DETERMINISTICO

Cabe señalar, que los valores de PC fueron promediados sobre cada región en análisis. Por lo cual, aunque los valores promedio sean entre 0.3 o 0.5, por ejemplo, es posible encontrar mayores valores de PC en áreas específicas en cada una de las nueve regiones.

Los mayores valores de PC fueron obtenidos sobre la costa norte, en donde, en general los experimentos con mejor performance fueron los 1, 2, 4, y 5; los cuales consideran la zona tropical del globo, y el Pacífico tropical. Los experimentos que consideran el área del Atlántico tropical norte, no mostraron correlaciones importantes sobre esta región del país. Los experimentos 2 y 5 resaltan con un mejor desempeño de pronóstico, donde los valores de correlación superaron en algunos modelos el valor de 0.6; no obstante, el experimento 5 (en donde se emplea la variable PP como predictor) es sobresaliente, donde se alcanzaron valores de PC cercanos a 0.8. Cabe señalar que, una mejor señal es adquirida en los experimentos en los que se consideraron netamente los valores de PP para el pronóstico estacional (4, 5, y 6). Finalmente, entre los mejores experimentos (2 y 5), los modelos CFSv2, CMC2, y el ensamble NMME alcanzaron mayores PC; en el experimento 2, el NMME mostró un mayor PC que el ERSSTv4.

Sobre las otras regiones, los valores de PC son menores que en la costa norte, oscilando los mejores valores entre 0.2 y 0.4. Siendo la costa sur y selva sur, con menor performance para un pronóstico determinístico.

De esta manera, en la costa centro, los experimentos 1 y 2 presentaron mejor performance, así como el experimento 5. Aunque en ambos casos los valores de PC no superaron el

valor de 0.3. En los experimentos 1 y 2, el NMME mostro mejores resultados que los datos del ERSSTv4. En el experimento 1 sobresale el NMME, y en el experimento 2, el CMC2; finalmente, en el experimento 5, el modelo más resaltante es el CFSv2, seguido de NASA y NMME.

Menores valores de PC fueron encontrados sobre la costa sur, en general, no se obtuvieron buenos resultados para esta región con ninguno de los experimentos, con excepción del experimento 5, donde sobre sale el modelo CFSv2 y CMC2, aunque con valores muy bajos de PC (0.2 aproximadamente). Cabe señalar, que a pesar que el modelo NASA en el experimento 3 (Atlántico tropical norte) mostró un PC cerca de 0.4, no es posible asumir una relación física entre ambas regiones.

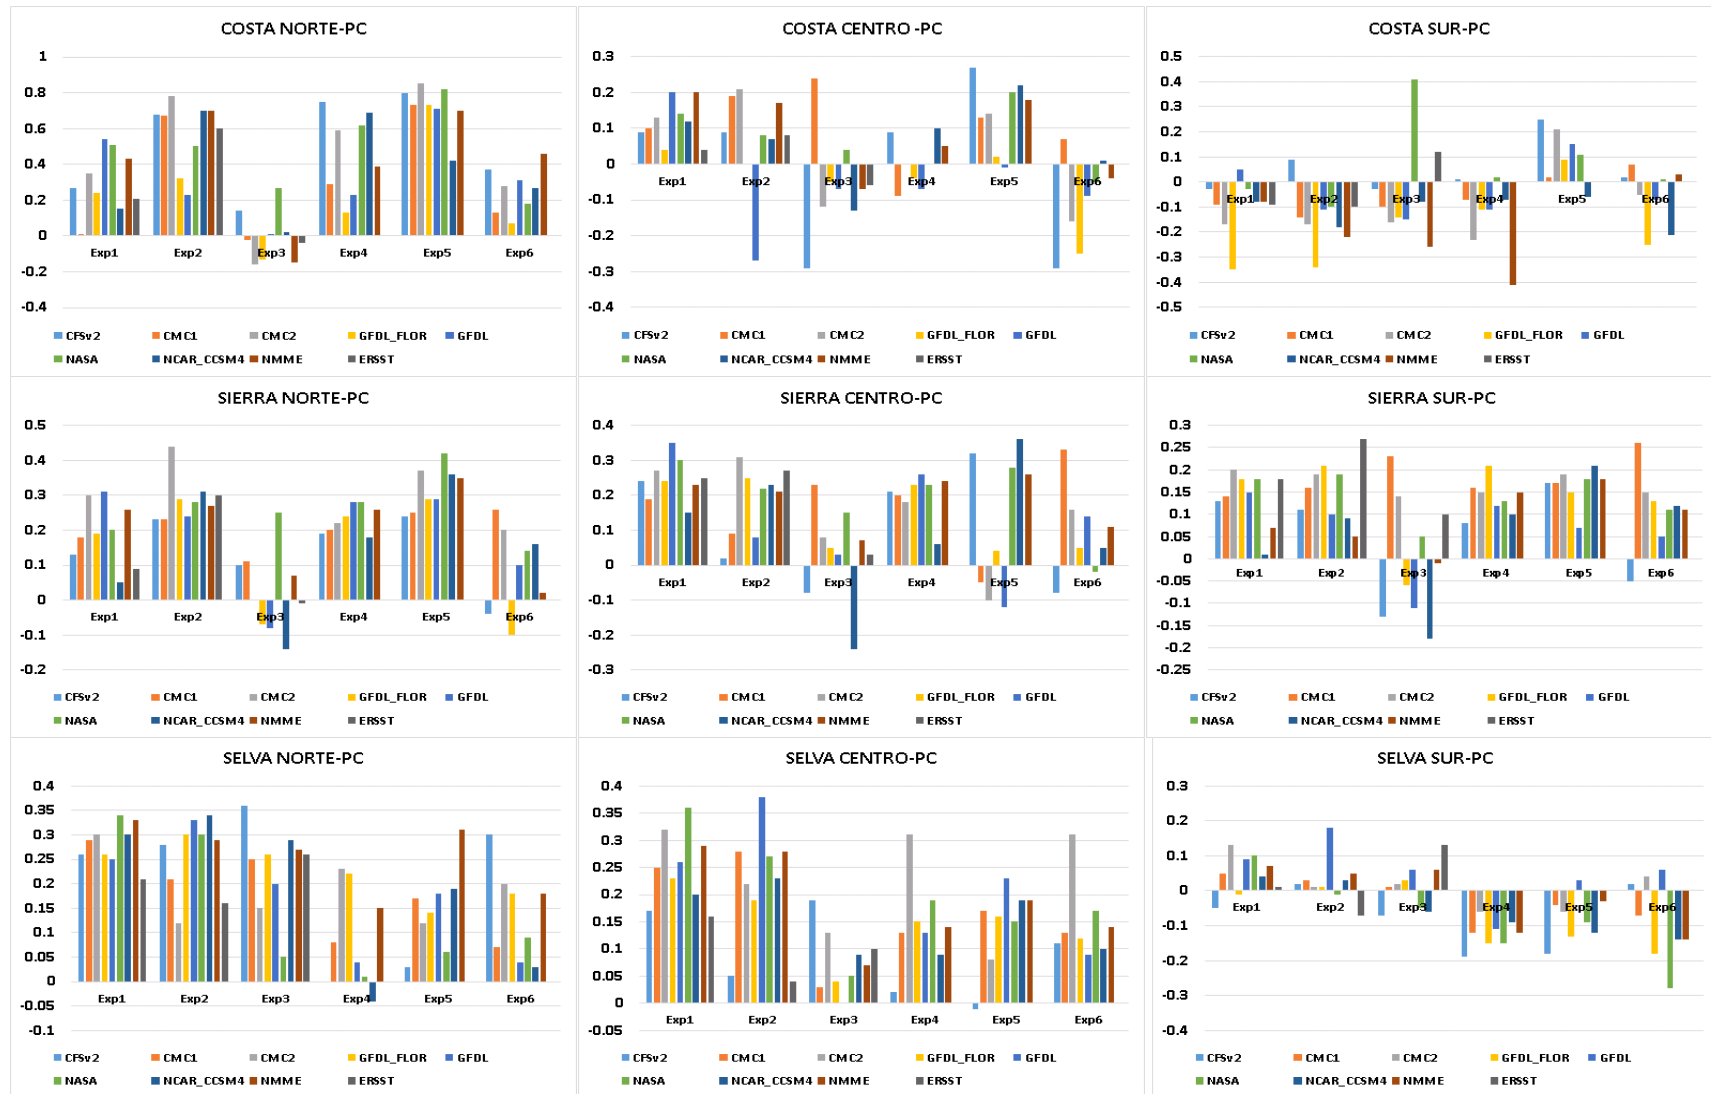


Figura 2. Correlación de Pearson promedio para cada región de estudio.

Sobre la sierra norte, los experimentos 1, 2, 4 y 5 fueron los más representativos; especialmente los 2 y 5, los cuales están asociados a la dinámica del Océano Pacífico tropical. Entre estos ambos experimentos, resaltan los modelos CMC2, NASA, NCAR-CCSM4, NMME, y ERSST. Los experimentos 3 y 6, no muestran una clara consistencia sobre su capacidad predictiva sobre esta región, dado que los valores de PC son muy variables entre los diferentes modelos e incluso la data ERSSTv4.

Para la sierra centro, los experimentos 1, 2, y 4 presentaron mayores valores de PC, donde los valores de correlación fueron positivos en todos los modelos en evaluación. Los modelos que sobresalen son NASA, CMC2, GFDL, y ERSST.

En la Sierra sur, Los experimentos con mejor performance fueron los números 1, 2, 4, y 5. Donde sobre todos los modelos, resalta la data observada ERSSTv4 en el experimento 2, con mayor valor de PC; seguidos de este, se encuentran: CMC2, GFDL-FLOR, y NASA.

Sobre la Selva norte, los experimentos 1, 2, y 3 presentaron mayores valores de PC. Con respecto a la variable SST proveniente del ERSSTv4, este muestra mayor PC entre el Atlántico tropical norte y los datos del predictante. Asimismo, dentro de los experimentos mencionados, los modelos con mejor performance fueron: NCAR-CCSM4, NMME, y GFDL-FLOR.

En la Selva centro, los mejores experimentos fueron los números 1 y 2, ambos, en general con valores similares de PC (entre 0.25 y 0.35). Entre estos resaltaron los modelos GFDL-FLOR, NASA, y CMC2.

Los resultados para la selva sur, ninguno de los experimentos mostró valores de PC satisfactorios.

4.2. PERFORMANCE DEL PRONÓSTICO PROBABILISTICO

Sobre la costa norte, los mejores experimentos fueron los números 2 y 5 (Pacífico tropical), en donde, resaltan los modelos CMC2, y GFDL-FLOR, respectivamente, con valores de 2AFC que sobrepasan el valor de 60. Estos resultados, en conjunto con lo obtenido en el análisis de pronóstico determinístico, están asociados a la estrecha la relación entre esta región del país y la dinámica en el Pacífico tropical, tal como señalan, por ejemplo, Garcia et al, 2007, y Luc Bourrel, 2014.

Por otro lado, para la región de costa central, los experimentos 1, 2, y 5, fueron los más resaltantes. Donde resaltan los modelos NCAR-CCSM4, NASA, CMC2, y NMME. Sin embargo, para la costa sur, solo el experimento 5, mostró mejor performance, siendo los modelos NASA, CMC1, y CFSv2 con mejor desempeño.

Para la sierra norte, el mejor experimento fue número 5, seguido del 2, 4, y 5. Entre estos, los modelos NASA, CMC2, GFDL, GFDL-FLOR, y NMME, obtuvieron mejores scores, cercanos al valor promedio de 70.

Por otra parte, para la sierra centro, el experimento 1 presentó un resultado más consistente, donde el pronóstico probabilístico por persistencia empleando datos ERSSTv4 mostró un desempeño similar al uso de los modelos globales norteamericanos, entre ellos, los modelos GFDL-FLOR, NMME, NASA, y CMC2 fueron los mejores.

Para el caso de la sierra sur, todos los experimentos muestran resultados similares con valores de 2AFC superiores a 50, y cercanos a 60, con excepción del experimento 3. Entre todos los experimentos y modelos, resalta el pronóstico por persistencia empleando datos ERSSTv4 en el experimento 2 (Pacífico tropical). Para este sector, si bien el océano Pacífico presenta el mayor performance, existe cierta capacidad predictiva probabilística por parte del Atlántico tropical norte. Los modelos americanos con mejor performance fueron: GFDL-FLOR, CMC1, CMC2, y NASA.

Para la parte de la selva norte, los experimentos 1 al 3, mostraron mejor performance, es decir empleando datos de TSM. Si bien los experimentos 1 y 2, mostraron mayor habilidad; el experimento del Atlántico nor-tropical (exp.3) muestra con los datos ERSSTv4, una mayor capacidad predictiva (pronóstico por persistencia). No obstante, entre los experimentos 1 y 2, los modelos NASA, GFDL, CMC1, CMC2, CFSv2 y NMME (el más resaltante) presentaron mejor desempeño.

Sobre la selva centro, los experimentos 1, 2, 4, y 5, presentaron mejor desempeño, principalmente los dos primeros. Sobresaliendo los modelos NMME, NASA, GFDL, y GFDL-FLOR.

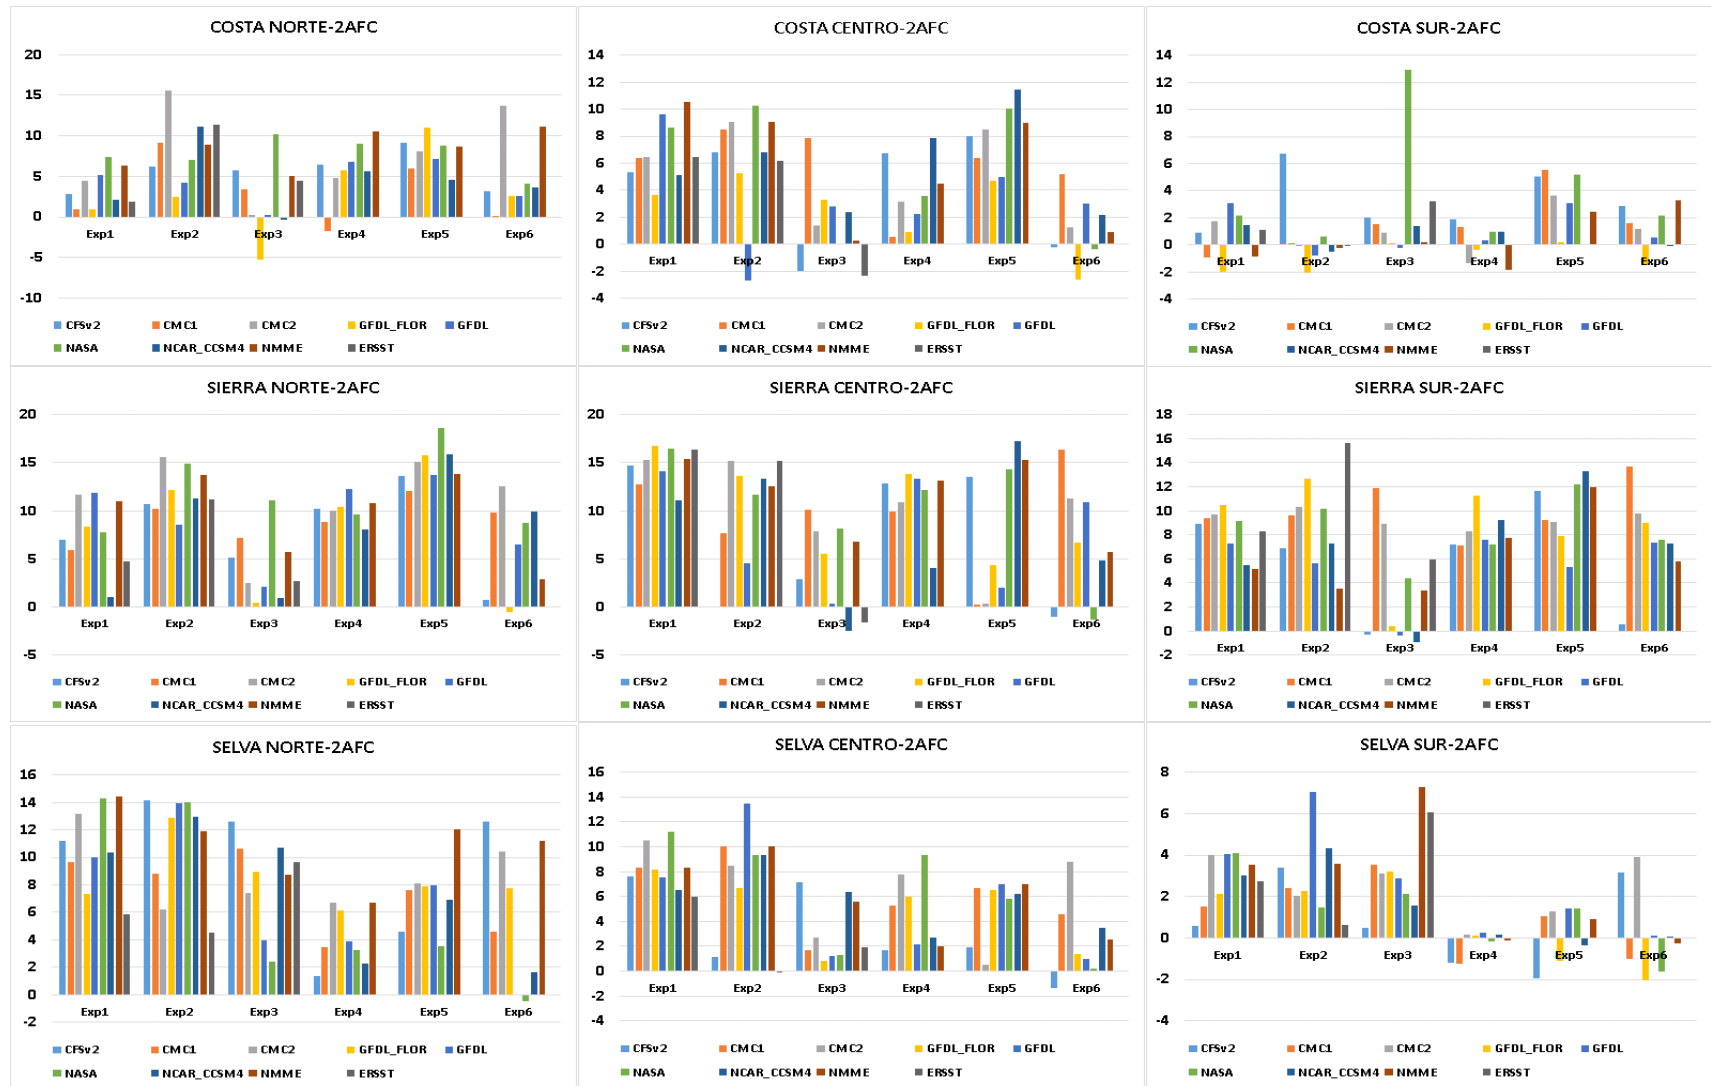


Figura 3. Valores promedio de 2AFC for forecast categories para cada región de estudio. A todos los valores de 2AFC se les ha restado el valor de 50.

Finalmente, para zona de selva sur, los mejores experimentos fueron 1, 2, y 3. Mostrando mejor desempeño el ensamble NMME, ERSSTv4, NASA, y GFDL. Es necesario mencionar, que en general las regiones de selva para el pronóstico probabilístico, la región Atlántico tropical norte obtuvo importantes scores 2AFC por encima de 50 (incluyendo en el pronóstico por persistencia empleando datos ERSSTv4). Esto principalmente sobre las zonas de selva norte y sur. Estos resultados, resalta la relación entre esta región y la amazonia peruana, la cual ha sido señalada en trabajos de Lavado 2013, Fernandes 2011, y White 2011.

V. CONCLUSIONES

En cuanto al pronóstico determinístico, la única región del país que poseyó mejores valores de PC (valores cercanos a 0.8) fue la costa norte, resultados que fueron obtenidos con experimentos asociados al área del Pacífico tropical, especialmente con los datos de PP de los modelos del NMME, sobresaliendo con un mejor desempeño los modelos CMC2 y CFSv2. En contraste, la región con menores valores de PC se encontraron sobre la costa y selva sur.

Por otro lado, en cuanto al performance del pronóstico probabilístico, en general, sobre la mayoría de regiones del país ha sido posible obtener valores de 2AFC por encima del valor de 50 (a excepción de la costa sur), lo cual indica que existe (con respecto a un pronóstico determinístico) mejor habilidad para realizar este tipo de pronóstico. Las áreas con mejor performance son sobre toda la sierra y la selva norte, incluso con valores cercanos a 70, señalando la ventaja de este tipo de pronóstico ante un mero pronóstico por climatología, estas obtenidas principalmente con experimentos que involucran el área tropical del globo y el Pacífico tropical. Sobre todos los modelos, sobresalen el CMC2, NASA, NMME, y los datos del ERSSTv4 (este último con desempeño sobresaliente en la sierra sur).

Cabe señalar que, a pesar de los bajos valores de PC obtenidos, y considerando los scores de 2AFC, los experimentos con mejor performance (independientemente de los modelos y/o de los datos observados empleados) fueron los asociados a la dinámica del Pacífico tropical, posicionando a esta área como una de las más influyentes en las precipitaciones de verano sobre el país. Asimismo, el Atlántico tropical norte, ha manifestado una influencia (en menor proporción que el Pacífico) importante sobre las lluvias de verano en la selva; los bajos valores de 2AFC sobre zonas de la selva centro y sur, pueden estar influenciados (en parte) a la menor densidad de datos observados, siendo en estas regiones los datos predominantemente provenientes de fuentes satelitales.

VI. RECOMENDACIONES

Dentro de los futuros pasos sugeridos para el reforzamiento de este estudio, se encuentra la validación de los EOF loadings (espacial y temporal) de las salidas de TSM y PP de los modelos del NMME durante el periodo de verano, a modo de verificar la veracidad de los patrones físicos que estos señalan, y que han sido usados como predictores; de esta manera, nos permitirá certificar el empleo de estos predictores. Del mismo modo, se recomienda la verificación de los datos PISCO, así como la comparación entre las métricas (PC y 2AFC) de los resultados grillados obtenidos y de datos observados de estación. Finalmente, se exhorta la replicación de estos procedimientos para otras estaciones del año, y para las variables de temperatura; así como, la realización de los análisis para la viabilidad de pronósticos con lead times tanto con datos observados como con los NMME.

VII. REFERENCIAS BIBLIOGRÁFICAS

1. Barnston, A. G., 1994. Linear statistical short-term climate predictive skill in the Northern Hemisphere. *J. Climate*, 7, 1513–1564. DOI: 10.1175/1520-0442(1994)0072.0.CO;2.
2. Barnston, A. G., W. Thiao, and V. Kumar, 1996: Long-lead forecasts of seasonal precipitation in Africa using CCA. *Wea. Forecasting*, 11, 506–520. DOI: 10.1175/1520-0434(1996)011,0506:LLFOSP.2.0.CO;2.
3. Fernandes, K., et al. 2011. North Tropical Atlantic influence on western Amazon fire season variability. *Geophysical Research Letters*, 38. DOI: 10.1029/2011GL047392.
4. Garcia, R., et al. 2007. A Chronology of El Niño Events from Primary Documentary Sources in Northern Peru. *Journal of Climate*, 21: 1948-1962. DOI: 10.1175/2007JCLI1830.1.
5. Kirtman, B. P., et al. 2014. The North American Multimodel Ensemble: Phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction. *Bull. Amer. Meteor. Soc.*, 95, 585–601. DOI: 10.1175/BAMS-D-12-00050.1.
6. Lavado, W., et al. 2013. ENSO impact on hydrology in Peru. *Advances in Geosciences*, 33:33-39. DOI: 10.5194/adgeo-33-33-2013.

7. Lavado W, Fernandez C, Vega F, Caycho T, Endara S, Huerta A, Obando OF. 2016. PISCO: Peruvian interpolated data of the SENAMHI's climatological and hydrological observations. Precipitación v1.0. Servicio Nacional de Meteorología e Hidrología, pp. 1–4.
8. Lazenby, M., et al. 2014. Seasonal temperature prediction skill over Southern Africa and human health. *Meteorological Applications*, 21: 963-974. DOI: 10.1002/met.1449.
9. Luc Borrel, et al. 2015. Low-frequency modulation and trend of the relationship between ENSO and precipitation along the northern to centre Peruvian Pacific coast. *Hydrological processes*, 29: 1252-1266. DOI: 10.1002/hyp.10247.
10. Ma, F., Ye, A., Deng, X., Zhou, Z., Liu, X., Duan, Q., Xu, J., Miao, C., Di, Z. and Gong, W. 2016. Evaluating the skill of NMME seasonal precipitation ensemble predictions for 17 hydroclimatic regions in continental China. *Int. J. Climatol.*, 36: 132–144. doi:10.1002/joc.4333.
11. Mason, S., Weigel, A. 2009. A Generic Forecast Verification Framework for Administrative Purposes. *Mon. Weather Rev.*, 137, 331–349. DOI: 10.1175/2008MWR2553.1.
12. Wassila, T., Barnston, A., Kumar, V. 1999. Predictions of African rainfall on the seasonal timescale. *Journal of geophysical research*, 104,24:589-597.
13. White, R., et al. 2011. The influence of tropical North Atlantic SST on precipitation in the Peruvian Amazon over the past ~1500 years. AGU Fall Meeting Abstracts. 1900.
14. Wilks, D. S., 2006. *Statistical Methods in the Atmospheric Sciences*. 2nd ed. International Geophysics Series, Vol. 91, Academic Press, 627 pp.