

Pronóstico trimestral estadístico y estadístico-dinámico del Servicio Meteorológico Nacional

Nota Técnica SMN 2022 - 118

Natalia Herrera¹

¹ Dirección Nacional de Ciencia e Innovación en Productos y Servicios. Dirección Central de Monitoreo del Clima, SMN

Enero 2022

Información sobre Copyright

Este reporte ha sido producido por empleados del Servicio Meteorológico Nacional con el fin de documentar sus actividades de investigación y desarrollo. El presente trabajo ha tenido cierto nivel de revisión por otros miembros de la institución, pero ninguno de los resultados o juicios expresados aquí presuponen un aval implícito o explícito del Servicio Meteorológico Nacional.

La información aquí presentada puede ser reproducida a condición que la fuente sea adecuadamente citada.

Resumen

Desde mediados de la década de 1990 en el Servicio Meteorológico Nacional de Argentina (SMN) se elaboran los pronósticos trimestrales de temperatura media y de precipitación acumulada por consenso. Para la elaboración de dicho pronóstico se tienen en cuenta las previsiones de otros centros o modelos climáticos y también los pronósticos estadístico y estadístico-dinámico que se generan en el organismo. En esta nota técnica se presenta el Modelo de pronóstico estadístico SMN-CPT y el Modelo de pronóstico estadístico-dinámico SMN-CPT.NMME. Se calibraron para cada trimestre del año y para cada región del territorio nacional.

Abstract

Since the mid-1990s, the National Meteorological Service of Argentina (SMN in spanish) produces mean temperature and accumulated precipitation consensus seasonal forecasts. For the elaboration of this forecast, the forecasts of other centers or climatic models are taken into account, as well as the statistical and statistical-dynamic forecasts that are produced in the organism. This technical note presents the SMN-CPT Statistical Forecast Model and the SMN-CPT.NMME Statistical-Dynamic Forecast Model. They were calibrated for each trimester of the year and for each region of the national territory.

Palabras clave: pronóstico trimestral, estadístico, estadístico-dinámico, Argentina.

Citar como: Herrera, N., 2022: Pronóstico trimestral estadístico y estadístico-dinámico del Servicio Meteorológico Nacional. Nota Técnica SMN 2022-118.

1. INTRODUCCION

Pronósticos más precisos de la precipitación acumulada y la temperatura media para los próximos tres meses representan un desafío para los principales centros que desarrollan pronósticos climáticos globales. Los beneficios de pronósticos más confiables son estratégicos para distintos sectores (agropecuario, energía, recursos hídricos, salud, entre otros) así como para la toma de decisiones de los administradores de emergencias en la planificación y mitigación de los impactos de sequías e inundaciones, por ejemplo. En este sentido, la iniciativa de agregación de modelos dinámicos constituye uno de los últimos avances en un intento por mejorar cada vez más la confiabilidad de los pronósticos, así como su horizonte de predictibilidad (pronósticos estacionales a intraestacionales). Incluso con avances notables en esta área, aún existen varias incertidumbres en los resultados de las predicciones (Ma y otros, 2014; Najafi y otros, 2015; Ahmadiyoun y otros, 2017) que dan espacio para el desarrollo/aplicación de técnicas de pos procesamiento que permitan incrementar la confiabilidad de estos pronósticos (Barnston y otros, 2017).

En términos generales, hay tres tipos de métodos que se pueden utilizar para realizar pronósticos estacionales: empírico (o estadístico), dinámico e híbrido (estadístico-dinámico). Los métodos empíricos utilizan relaciones estadísticas entre los predictores - las variables utilizadas para hacer el pronóstico - y el pronóstico - la variable a pronosticar o predictando -, generalmente involucrando algún tipo de modelo de regresión utilizando datos de observación. Los predictores se identifican mediante el análisis físico de los mecanismos que controlan la predicción. Por ejemplo, en muchos Foros Regionales de Perspectivas Climáticas de todo el mundo se utiliza la Temperatura Superficial del agua de Mar (TSM) del mes anterior como campo predictor para pronosticar la precipitación y la temperatura para el trimestre siguiente.

Según la Guía de la Organización Meteorológica Mundial sobre prácticas operativas para la predicción estacional objetiva (WMO, 2020), algunas ventajas de los métodos empíricos son que requieren bajos recursos informáticos y son fáciles de implementar operativamente, están diseñados para ser consistentes con las observaciones (ya están corregidos por sesgo, al menos con respecto a los valores medios), y ofrecen predicciones en términos tanto de valores determinísticos como de probabilidades. Algunas desventajas son que los métodos empíricos más comunes asumen estacionalidad en el sistema climático y, por lo tanto, no pueden representar adecuadamente la presencia de tendencias y otras variaciones, tienden a tener problemas para reproducir la varianza observada de los predictores y, dado que generalmente se basan en relaciones lineales, les resulta difícil representar interacciones no lineales dentro del sistema climático. Dadas las continuas mejoras en los sistemas de predicción estacional basados en modelos dinámicos, se espera que en el futuro, estos sistemas sean más efectivos que los métodos de predicción empíricos para realizar pronósticos estacionales precisos.

Aunque los métodos empíricos tienden a utilizar campos observados (por ejemplo, TSM o variables de circulación atmosférica) como predictores, también pueden utilizar la salida de modelos dinámicos. Los campos de precipitación predichos dinámicamente, por ejemplo, se pueden usar como predictores, mientras que la precipitación observada se puede usar como predicción. Este método "híbrido" también puede corregir los sesgos del modelo. Los sistemas de predicción dinámica también representan los numerosos procesos climáticos que pueden influir en la variabilidad estacional en una región de manera más completa que los enfoques empíricos / estadísticos. Los modelos dinámicos generan predicciones a partir de los principios físicos fundamentales, por lo que son potencialmente capaces de generar una amplia gama de posibles comportamientos, a diferencia de los modelos estadísticos, que están limitados por datos de observación. Los sistemas dinámicos de predicción estacional también son capaces de predecir patrones climáticos sin precedentes (o raros) que no han ocurrido en los datos históricos, por ejemplo, tendencias recientes de

calentamiento en la temperatura o teleconexiones asociadas con eventos El Niño/Oscilación del Sur (ENOS) extremos.

Una desventaja de usar métodos dinámicos es que los modelos dinámicos tienen sesgos en la representación de la media y varianza de variables como precipitación, nubosidad y nieve, y con respecto a la reproducción correcta de los patrones espaciales (por ejemplo, ubicación, extensión, forma) de las variables atmosféricas y oceánicas, desde la TSM hasta los campos de circulación y las teleconexiones asociadas. La necesidad de evaluar estos sesgos a través de pronósticos retrospectivos (hindcasts) de temporadas pasadas y compararlos con los resultados observados también aumenta sustancialmente el costo y la complejidad de los sistemas dinámicos.

En la actualidad, para algunas regiones y / o temporadas, los modelos dinámicos pueden no ser tan hábiles como los modelos estadísticos (o empíricos). En tales casos, para proporcionar la mejor información de pronóstico estacional, se puede utilizar una combinación objetiva de modelos empíricos (estadísticos) y dinámicos. Sin embargo, los modelos estadísticos deben estar debidamente entrenados y deben tener una validación cruzada para evaluar adecuadamente su desempeño pasado. El uso de modelos estadísticos solo debe considerarse una medida provisional dados los avances rutinarios en los modelos dinámicos (WMO, 2020).

El pronóstico climático estacional del SMN consiste en un pronóstico probabilístico por consenso elaborado por la Dirección Central del Monitoreo del Clima en conjunto con la Dirección Nacional de Servicios Sectoriales, en el cual participan también otras instituciones. La presentación del pronóstico trimestral corresponde a un campo o mapa con un sistema de probabilidades de tres categorías (“superior a lo normal”, “normal” e “inferior a lo normal”). Dicho pronóstico se realiza mensualmente para todo el país para las variables temperatura media y precipitación acumulada. Está basado en un consenso consolidado a partir de diversas fuentes: las previsiones numéricas experimentales de los principales modelos globales de simulación del clima y modelos estadísticos nacionales, sumado al análisis de la evolución de las condiciones oceánicas y atmosféricas. Es subjetivo ya que su elaboración se basa en el análisis que realizan los expertos no sólo de las condiciones atmosféricas-oceánicas prevalentes, sino también de las salidas disponibles de diversos modelos climáticos. Si bien todos los expertos utilizan como guía o referencia la misma información, sus valoraciones son únicas y difieren entre sí producto de su experiencia y percepción. Los expertos cuentan con información reciente de verificación del pronóstico estacional por consenso elaborado por el SMN y de las previsiones de otros centros o modelos climáticos, para ser usados con fines comparativos (Poggi y otros, 2021).

En este trabajo se presentan dos modelos de pronóstico trimestral que genera el SMN cada mes: SMN-CPT (estadístico) y SMN-CPT.NMME (estadístico-dinámico). Ambos emplean la herramienta de predicción climática Climate Predictability Tool (CPT; Mason y otros, 2017) desarrollada y puesta a disposición por el International Research Institute for Climate and Society (IRI) y la técnica de Análisis de Correlación Canónica (ACC; Barnston, 1994) para realizar predicciones. El CPT es un software que facilita el proceso de calibración de pronósticos con ACC. El software fue desarrollado en el lenguaje de programación Fortran 90 y adaptado para uso práctico en los sistemas operativos Windows y Linux. Es capaz de producir predicciones climáticas usando correcciones estadísticas de los resultados de modelos climáticos globales, o producir predicciones usando campos de temperatura de la superficie del mar o predictores similares (altura geopotencial, componentes zonales y meridionales del viento a diferentes niveles atmosféricos, etc.). El ACC es una de las técnicas disponibles en el software para generar predicciones empíricas o calibrar las salidas de modelos dinámicos, y la que se utilizó en estos modelos de pronóstico.

2. DATOS

2.1 Predictandos

Se utilizan datos mensuales de precipitación acumulada de 79 estaciones (Figura 1 izq.) y datos mensuales de temperatura media de 67 estaciones (Figura 1 centro der.). Para poder estudiar los predictores de cada área climática por separado se hizo una regionalización con el método Kmeans (Hartigan, 1975; Hartigan y otros, 1979). Para la precipitación, se utilizaron las series de anomalías mensuales de precipitación y se plantearon 6 regiones (Figura 1 centro izq.) mientras que para la temperatura media, se utilizaron las anomalías mensuales y se dispusieron 12 regiones (Figura 1 der.). Los datos iniciales para analizar los hindcasts comprenden el periodo 1961-2018.




Fig. 1: Estaciones meteorológicas del SMN y las regiones consideradas por los modelos SMN-CPT y SMN-CPT.NMME para el pronóstico de la precipitación (izq. y centro izq.) y de la temperatura media (der. y centro der.).

2.2 Predictores

Se utilizan datos de reanálisis disponibles en la Biblioteca de Datos del IRI (<https://iridl.ldeo.columbia.edu/>), tanto de variables atmosféricas (HG500: altura geopotencial en 500 hPa, U250: viento zonal en 250 hPa, V850: viento meridional en 850 hPa y W700: velocidad vertical en 700 hPa; Kalnay y otros, 1996), como de variables oceánicas (TSM: temperatura superficial del agua de mar; Reynolds y otros, 2002) como predictores. Los datos de las variables atmosféricas se actualizan a nivel diario, con un retraso de 3 a 4 días al día actual y los datos oceánicos se actualizan a nivel semanal, con un retraso de 2 a 3 días. Se utilizan los datos promediados del mes anterior al trimestre que se quiere pronosticar. Por ejemplo, si se quiere pronosticar el trimestre septiembre-octubre-noviembre (SON) se toman datos de agosto (en el caso de las variables atmosféricas se toma el promedio de datos diarios y en el caso de la variable oceánica se toma promedio de datos semanales). También se utilizan los datos mensuales históricos desde 1961. En algunas ocasiones estos datos no estuvieron disponibles a la hora de realizar el pronóstico, y se recurrió a

otras fuentes de datos, como el de la National Oceanic and Atmospheric Administration Physical Sciences Laboratory (NOAA PSL; <https://psl.noaa.gov/>).

El North American Multi-Model Ensemble (NMME) es una iniciativa de la NOAA en los Estados Unidos, que combina pronósticos de los modelos operativos de los Centros de Producción Globales para Pronósticos a Largo Plazo (GPC-LRF, por sus siglas en inglés) de Washington y Montreal y modelos desarrollados en la NASA (National Aeronautics and Space Administration), GFDL (Geophysical Fluid Dynamics Laboratory) y NCAR (National Center for Atmospheric Research) (Kirtman y otros, 2014). Aunque la combinación específica de modelos ha evolucionado desde que NMME se estableció en 2011, ha habido consistentemente de seis a ocho modelos contribuyentes con aproximadamente 100 miembros del conjunto en total. Al momento de la evaluación se utilizaron los modelos CFSv2, CMC1, CMC2, GFDL, GFDL-FLOR, NASA y NCAR-CCSM4. NMME surgió de la necesidad de evaluar los pronósticos y la previsibilidad climática intraestacional e interanual, para satisfacer las necesidades regionales específicas de pronósticos estacionales y para apoyar la toma de decisiones por parte de una gran comunidad de usuarios de información climática. NMME demuestra ser más eficaz en comparación con cualquiera de los modelos individuales que lo componen. El CPC (Centro de Predicción del Clima) de la NOAA es el organismo responsable de poner a disposición de los usuarios de forma gratuita tanto los hindcasts como los pronósticos de cada modelo individual, así como el conjunto (NMME), y los centros de pronóstico del clima lo utilizan cada vez más de manera operativa en todo el mundo (Kirtman y otros, 2014).

Para el modelo SMN-CPT.NMME, se agrega el NMME como un predictor más a los predictores del modelo SMN-CPT que presentaron mejores métricas de predicción para cada región y trimestre (ver sección 3, metodología). Los datos del NMME se toman de <https://ftp.cpc.ncep.noaa.gov/International/nmme/> y están disponibles en dos formatos, binario para usar con el software GrADS y ascii para usar con el software CPT. Se utilizan los pronósticos retrospectivos (hindcasts) y operativos del NMME. Al momento de la evaluación de los predictores, los hindcasts estaban disponibles para 1982-2010/1983-2011, pero desde enero de 2021 se cuenta con información de los hindcasts para 1991-2020/1992-2021. Desde el mes de inicialización se cuenta con hindcasts de hasta seis meses/trimestres. Las predicciones en tiempo real para cada mes son realizadas por CPC/NCEP y están disponibles entre los días 8 y 11 de cada mes, en tres variables: temperatura de la superficie del mar (*sst*), temperatura promedio a 2 metros (*tmp2m*) y tasa de precipitación (*precip*), en una resolución global de 1.0°x1.0° de latitud/longitud, para todos los miembros (modelos) del conjunto (NMME). Para el modelo SMN-CPT.NMME, se usan los datos de *tmp2m* y de *precip* para pronosticar temperatura media y precipitación acumulada, respectivamente.

3. METODOLOGÍA

3.1 Calibración de pronósticos con ACC

Los pronósticos crudos de un modelo climático global pueden presentar tendencias indeseables (sesgos) y, a menudo, no muestran una capacidad superior a una predicción simple basada en la climatología (Shukla y otros, 2013; Schepen y otros, 2014). Por lo tanto, existen importantes beneficios al aplicar metodologías de pos procesamiento a las predicciones climáticas.

Se pueden utilizar varias técnicas para resolver tales problemas, mientras se busca extraer la máxima habilidad de las predicciones (Zhao y otros, 2017). Dichas técnicas van desde combinar diferentes modelos utilizando el enfoque bayesiano para obtener mejores resultados (Coelho y otros, 2006; Coelho y otros, 2007),

regresión por conjuntos (Unger y otros, 2009; Ou y otros, 2016; Collins, 2017), modelos de probabilidad conjunta (Wang y otros, 2009; Wang y otros, 2011), entre otros métodos estadísticos de pos procesamiento o calibración (Gneiting y otros, 2005; Wilks y otros, 2007; Sachindra y otros, 2013; Schepen y otros, 2014; Benestad y otros, 2015; Zhang y otros, 2017; Narapusetty y otros, 2018). Entre las diversas técnicas existentes para corregir errores sistemáticos en los modelos, se usará ACC.

El ACC es una de las técnicas para el pos procesamiento de los resultados del modelo climático presentes en el software CPT. Es un método estadístico que identifica un par de patrones en dos conjuntos de datos multivariados y genera variables transformadas que proyectan los patrones de la serie original. El ACC se aplica como un método de reducción de escala y corrección de sesgo de los resultados del modelo, mejorando las predicciones del modelo utilizando relaciones estadísticas entre las variables observadas y predichas por el modelo. A menudo, estas relaciones estadísticas tienen una base física, absorbiendo señales de fenómenos a gran escala (por ejemplo: ENOS), que influyen en los pronósticos.

El ACC se puede utilizar de dos maneras en CPT, la primera, que es la que se usa para el Modelo SMN-CPT, como un modelo de pronóstico puramente estadístico que relaciona patrones de anomalías en las observaciones (por ejemplo anomalías de la TSM) con patrones de anomalías climáticas trimestres posteriores (por ejemplo anomalías de precipitación) basados en un período largo de años, sin involucrar ningún modelo dinámico (Chu y otros, 1994; Chu 1998; Landman y otros, 1999; Collins y otros, 2004; Chowdhury y otros, 2007; Juneng y otros, 2008). La segunda forma de utilizar ACC, es la que se usa para el Modelo SMN-CPT.NMME, es relacionar los datos crudos del pronóstico proveniente del modelo NMME para la precipitación y temperatura del primer trimestre iniciados en el mes anterior con las observaciones de precipitación y temperatura correspondiente a cada trimestre en un período retrospectivo (Busuioc y otros, 2008; Lim y otros, 2011; Barnston y otros, 2017).

En ACC se realiza una pre-ortogonalización usando el análisis de funciones ortogonales empíricas (EOF, por sus siglas en inglés), también llamadas componentes principales, por separado de los hindcasts del modelo (variable X, o predictor) y las observaciones correspondientes (variable Y, o predictando). El conjunto de series temporales de las componentes principales más importantes de estas EOF se utiliza como entrada para ACC (Barnett y otros, 1987). Esta metodología reduce el número de variables utilizadas por el ACC al tiempo que conserva patrones de variabilidad más coherentes. El CPT aplica el preprocesamiento EOF antes del método ACC y luego estima el modelo mediante un proceso de validación cruzada (Barnston y otros, 1993; Tippett y otros, 2008). Es decir, el conjunto de datos (hindcasts) para estimar el modelo se divide en subconjuntos mutuamente excluyentes, de modo que algunos se utilizarán para estimar el modelo y el conjunto restante para la validación. El método de validación cruzada se caracteriza por este proceso de entrenamiento y validación, repitiéndose hasta que todos los conjuntos se hayan utilizado en algún momento para validar el modelo sin haber sido utilizados para entrenarlo. Este proceso permite la validación óptima de un modelo utilizando todos los datos disponibles para estimar los parámetros. Es muy útil para validación de pronósticos climáticos que tiene series de datos muy cortas para validar (Barnston y otros, 2017).

3.2 Análisis de los mejores predictores para cada trimestre y región

Para el Modelo SMN-CPT se cuenta con 5 predictores: HG500, U250, V850, W700 y TSM, 2 predictandos: temperatura media y precipitación acumulada, divididos en 12 y 6 regiones respectivamente, y 12 trimestres del año: EFM, FMA, MAM, AMJ, MJJ, JJA, JAS, ASO, SON, OND, NDE, DEF.

Por lo tanto, para cada una de las regiones de cada predictando y trimestre del año, se exploraron individualmente cada uno de los 5 predictores atmosféricos/oceánicos. Se buscaron las áreas (en formato rectangular) del planeta con buena correlación y una relación física esperable. Para esto se entrenó el modelo desde 1961 y se analizaron los hindcasts del período 1986-2018 (33 años), de los cuales se obtuvieron algunas métricas de verificación del modelo aplicables a pronósticos determinísticos:

- ✓ CORR (Coeficiente de correlación - mide la coherencia temporal entre los valores pronosticados y los valores observados),
- ✓ RMSE (Root Mean Square Error - mide la diferencia entre los valores pronosticados y los valores observados),
- ✓ **MSSS** (Mean Square Skill Score - es esencialmente el error cuadrático medio (MSE, por sus siglas en inglés) de los pronósticos en comparación con el MSE de la climatología).

También se calcularon otras métricas aplicables a pronósticos probabilísticos:

- ✓ RPS (Ranked Probability Score - mide el desempeño del modelo por la diferencia de la distribución pronosticada y la distribución empírica),
- ✓ RPSS (Ranked Probability Skill Score - mide el error cuadrado acumulativo entre las probabilidades categóricas pronosticadas y observadas en relación con un pronóstico de referencia).

Y para cada una de las categorías pronosticadas (inferior a lo normal, normal y superior a lo normal):

- ✓ BS (Brier Score - mide la precisión de los pronósticos probabilísticos),
- ✓ BSS (Brier Skill Score - mide la precisión del pronóstico cuantificando la diferencia media en las probabilidades pronosticadas menos la ocurrencia o no ocurrencia del fenómeno pronosticado),
- ✓ **ROC Area** (Receiver Operating Characteristic Area - mide la habilidad del pronóstico en discriminar un evento de un no evento. Es precisamente el área bajo la curva ROC/Diagrama ROC, resume la Curva ROC en un escalar),
- ✓ ROCSS (ROC Skill Score – es una transformación del ROC Area).

Además de todas estas métricas se graficaron **Diagramas ROC** (Figura 2 - mide la capacidad de los pronósticos para distinguir un evento de un no evento, comparando la tasa de pronósticos correctos versus la tasa de pronósticos erróneos) y **Diagramas de atributos o confiabilidad** (Figura 3 - mide la confiabilidad y la resolución de las predicciones, establece con qué frecuencia ocurre una probabilidad de pronóstico) para cada una de las 3 categorías pronosticadas, diagramas x-y de los valores pronosticados vs. los valores observados para cada estación meteorológica y período para el cual se realizan los hindcasts. Según Mason (2018), las métricas remarcadas en negrita constituyen el conjunto mínimo de procedimientos que todos los centros operativos de pronóstico deben esforzarse por calcular.




Fig. 2: Ejemplo de diagrama ROC correspondiente a la Región 3 de precipitación del trimestre SON.

En general, un período de al menos 30 años de hindcasts se suele considerar una muestra adecuada para la estimación de habilidades y corrección sistemática de errores. El Sistema de Verificación Estandarizado de la Comisión de Sistemas Básicos de la OMM para Pronósticos a Largo Plazo (SVSLRF, por sus siglas en inglés) recomienda que el período de hindcasts sea tan largo como fuera posible (WMO, 2019). Se necesita un período largo de hindcasts para capturar una muestra estadística adecuada de las influencias de la variabilidad del clima (como el ENOS) que proporciona previsibilidad, especialmente para variables más complejas como la precipitación. Las recomendaciones de Mason (2018) están destinadas a complementar el SVSLRF.




Fig. 3: Ejemplo de diagrama de atributos o confiabilidad para cada una de las 3 categorías pronosticadas correspondiente a la Región 3 de precipitación del trimestre SON.

El análisis de modelos con mayor destreza estará guiado por métricas estadísticas que medirán la calidad de los pronósticos determinísticos y probabilísticos. Según la naturaleza del pronóstico (determinístico o probabilístico), se requieren métodos de verificación ligeramente diferentes. Un pronóstico determinístico es un modelo cuya solución para determinadas condiciones es única y siempre la misma, no contempla la existencia de azar ni el principio de incertidumbre. Da como resultado el valor de la variable que se pronostica. Un pronóstico probabilístico cuantifica el nivel de incertidumbre asociado a la ocurrencia de un evento determinado, es una herramienta fundamental de apoyo a la toma de decisiones. Da como resultado las probabilidades de ocurrencia para cada una de las categorías de la variable que se pronostica. La Tabla 1 enumera las métricas que se calcularon, junto con la naturaleza del pronóstico y los rangos posibles que tiene cada métrica, así como también el valor óptimo para cada métrica.

Tabla I: Métricas calculadas y sus rangos de valores posibles y óptimos.

Métrica	Naturaleza del pronóstico	Valores	Valor Óptimo
CORR	determinístico	-1 a 1	1
MSSS	determinístico	-inf a 1	1 (< 0 es menos preciso que la climatología)
RMSE	determinístico	0 a inf	0
RPS	probabilístico	0 a 1	0
RPSS	probabilístico	-inf a 1	1
Brier Score	probabilístico	0 a 1	0
Brier Skill Score	probabilístico	-inf a 1	1
ROC Area	probabilístico y determinístico	0 a 1	1 (< 0.5 sin skill)
ROC Skill Score	probabilístico	-1 a 1	1

3.3 Elección de los mejores predictores

Se busca tener para cada una de las variables a pronosticar (temperatura media y precipitación acumulada) y para cada una las distintas regiones del país (12 regiones de temperatura media y 6 regiones de precipitación acumulada) el mejor modelo de pronóstico para cada trimestre del año (12 trimestres). Para lograr esto, en principio se trabajó individualmente con cada uno de los 5 predictores para cada región/variable/trimestre.

Para algunas regiones se encontró más de un área con buena correlación para el mismo trimestre y la misma variable predictora. En ese caso se eligió el área que tuviera las mejores métricas de verificación. Éstas se calcularon para cada estación meteorológica por separado (un ejemplo se puede visualizar en la Tabla II).

Una vez que se obtuvieron los mejores predictores individuales para cada región/variable/trimestre se compararon las métricas de los 5 predictores, y se plantearon nuevos modelos con las mejores combinaciones entre predictores. Por ejemplo, si la Región 3 de precipitación del trimestre SON tuvo muy buenas métricas con los predictores TSM y W700, se volvía a correr el modelo con estos 2 predictores combinados. Las métricas resultantes se compararon con las originales de cada modelo de predictores individuales, y se definió si el mejor modelo era tomar solamente TSM, o solamente W700, o tomar los 2 predictores a la vez. En este caso resultó la mejor combinación con los 2 predictores combinados.

De esta forma se terminó de conformar el modelo final para cada región/variable/trimestre. Algunas regiones/variables/trimestres obtuvieron un solo predictor, otras 5 predictores, etc.

Tabla II: Métricas calculadas para la Región 3 de precipitación del trimestre SON.

Station	General metrics					Category-specific metrics											
						Below normal				Near normal				Above normal			
						ROC				ROC				ROC			
	CORR	MSSS	RMSE	RPS	RPSS	BS	BSS	Area	ROCSS	BS	BSS	Area	ROCSS	BS	BSS	Area	ROCSS
E87097	0.379	0.135	168.561	0.201	-0.133	0.144	-0.349	0.698	0.397	0.242	0.010	0.560	0.120	0.258	-0.039	0.685	0.370
E87148	0.553	0.277	92.127	0.190	0.084	0.144	0.136	0.923	0.846	0.227	-0.023	0.607	0.215	0.244	0.015	0.778	0.556
E87155	0.579	0.322	97.878	0.176	0.154	0.115	0.311	0.907	0.813	0.221	0.007	0.483	-0.033	0.232	0.063	0.674	0.348
E87162	0.528	0.269	92.942	0.185	0.034	0.182	0.006	0.715	0.430	0.281	-0.126	0.621	0.243	0.186	0.065	0.671	0.343
E87166	0.506	0.235	117.134	0.224	-0.079	0.196	-0.175	0.720	0.440	0.228	-0.026	0.545	0.091	0.259	-0.044	0.659	0.319
E87178	0.409	0.061	152.296	0.215	-0.136	0.166	-0.292	0.714	0.429	0.255	-0.103	0.456	-0.087	0.262	-0.049	0.702	0.404
E87187	0.683	0.464	126.912	0.165	0.186	0.153	0.168	0.845	0.690	0.286	-0.169	0.647	0.293	0.184	0.171	0.872	0.744
E87270	0.643	0.389	95.570	0.174	0.198	0.144	0.317	0.817	0.635	0.230	0.007	0.643	0.286	0.199	0.105	0.719	0.438
E87289	0.647	0.396	117.503	0.219	0.050	0.228	0.045	0.777	0.554	0.198	0.004	0.593	0.185	0.218	0.018	0.843	0.686
E87393	0.620	0.382	118.607	0.194	0.154	0.195	0.076	0.726	0.452	0.184	-0.004	0.600	0.200	0.196	0.208	0.781	0.563
E87395	0.547	0.296	136.513	0.187	0.077	0.154	0.161	0.715	0.430	0.288	-0.179	0.553	0.105	0.227	-0.020	0.723	0.446

Para el Modelo SMN-CPT.NMME los predictores están conformados por los predictores finales del Modelo SMN-CPT y se le suma el predictor del NMME. Entonces para cada región/variable/trimestre se evaluó entre las siguientes 3 regiones cual era el mejor predictor del NMME:

- ✓ Argentina: xmin: 285; xmax: 310, ymin: -60, ymax: -20
- ✓ Sudamérica: xmin: 280; xmax: 325, ymin: -60, ymax: 10
- ✓ Sudamérica + Océano Pacífico: xmin: 180; xmax: 325, ymin: -60, ymax: 10

La selección de la mejor región fue a través del coeficiente de correlación entre los datos observados y los datos de los hindcasts del NMME.

Los resultados de la verificación de las series de pronósticos para los Modelos SMN-CPT y SMN-CPT.NMME desde enero-febrero-marzo 2019 hasta abril-mayo-junio de 2021 se encuentran en Poggi y otros (2021).

4. DISCUSIÓN Y CONCLUSIONES

En este trabajo se presentan dos Modelos de pronóstico trimestral que se generan mes a mes en el Servicio Meteorológico Nacional, los cuales son considerados -entre otros modelos- a la hora de realizar el pronóstico trimestral por consenso. Uno es estadístico SMN-CPT y el otro es estadístico-dinámico SMN-CPT.NMME. Ambos emplean la herramienta de predicción climática CPT (Climate Predictability Tool) y la técnica de Análisis de Correlación Canónica (ACC) para realizar predicciones empíricas o calibrar las salidas de modelos dinámicos. El CPT es un software que facilita el proceso de calibración de pronósticos con ACC. Es capaz de producir predicciones climáticas usando correcciones estadísticas de los resultados de modelos climáticos globales, o producir predicciones usando campos de variables atmosféricas u oceánicas. El SMN-CPT se utiliza desde hace más de 10 años, y a partir de 2019 se hizo un exhaustivo análisis de los predictores a través del análisis de las métricas estadísticas que miden la calidad de los pronósticos determinísticos y

probabilísticos buscando tener el mejor modelo de pronóstico para cada región del país y cada trimestre del año. También a partir de 2019, en un intento por mejorar cada vez más la confiabilidad de los pronósticos, se incorporaron los modelos dinámicos del NMME (North American Multi-Model Ensemble) a través del Modelo SMN-CPT.NMME, logrando así tener un pronóstico estadístico-dinámico ("híbrido"). Este método "híbrido" también puede corregir los sesgos del modelo. Los modelos dinámicos generan predicciones a partir de los principios físicos fundamentales, por lo que son potencialmente capaces de generar una amplia gama de posibles comportamientos, a diferencia de los modelos estadísticos, que están limitados por datos de observación. En la actualidad, para algunas regiones y / o temporadas, los modelos dinámicos pueden no ser tan hábiles como los modelos estadísticos. En tales casos, para proporcionar la mejor información de pronóstico estacional, se puede utilizar una combinación objetiva de modelos estadísticos y dinámicos. El uso de modelos estadísticos solo debe considerarse una medida provisional dados los avances rutinarios en los modelos dinámicos.

5. REFERENCIAS

- Ahmadalipour A., H. Moradkhani, and M.C. Demirel, 2017: A comparative assessment of projected meteorological and hydrological droughts: Elucidating the role of temperature. *Journal of Hydrology* 553, 785-797.
- Barnett T.P., R. Preisendorfer, 1987: Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. *Monthly Weather Review* 115, 1825-1850.
- Barnston A.G, H.M. van den Dool, 1993: A degeneracy in cross-validated skill in regression-based forecasts. *Journal of Climate* 6, 963-977.
- Barnston A.G, M.K. Tippett, 2017: Do Statistical Pattern Corrections Improve Seasonal Climate Predictions in the North American Multimodel Ensemble Models?. *Journal of Climate* 30, 8335-8355.
- Barnston A.G., 1994: Linear Statistical Short-Term Climate Predictive Skill in the Northern Hemisphere. *J. Climate*, 7, 1513–1564, [https://doi.org/10.1175/1520-0442\(1994\)007<1513:LSSTCP>2.0.CO;2](https://doi.org/10.1175/1520-0442(1994)007<1513:LSSTCP>2.0.CO;2).
- Benestad R., D. Chen, A. Mezghani, L. Fan, K. Parding, 2015: On using principal components to represents stations in empirical-statistical downscaling, submitted to *Tellus A*.
- Busuioc A., R. Tomozeiu, C. Cacciamani, 2008: Statistical downscaling model based on canonical correlation analysis for winter extreme precipitation events in Emilia-Romagna region. *International Journal of Climatology* 28(4), 449-464.
- Chowdhury Md.R., P-S. Chu, T. Schroeder, N. Colasacco, 2007: Seasonal sea-level forecasts by canonical correlation analysis-an operational scheme for the U.S.-affiliated Pacific Islands. *International Journal of Climatology* 27, 1389-1402.
- Chu P-H., 1998: Short-Term climate prediction of Mei-Yu rainfall for Taiwan using canonical correlation analysis. *International Journal of Climatology* 18, 215-224.
- Chu P-H., Y. He, 1994: Long-Range prediction of Hawaiian winter rainfall using canonical correlation analysis. *International Journal of Climatology* 14, 659-669.

- Coelho C.A.S., D.B. Stephenson, F.J. Doblas-Reyes, M. Balmaseda, R. Graham, 2007: Integrated seasonal climate forecasts for South America. *CLIVAR Exchanges* 12, 13-19.
- Coelho C.A.S., D.B. Stephenson, M. Balmaseda, F.J. Doblas-Reyes, G.J. van Oldenborgh, 2006: Toward an Integrated Seasonal Forecasting System for South America. *Journal of Climate* 19(15), 3704-3721.
- Collins D.C., C.J. Reason, F. Tangang, 2004: Predictability of Indian Ocean sea surface temperature using canonical correlation analysis. *Climate Dynamics* 22, 481-497.
- Collins D.C., 2017: Assessment of ensemble regression to combine and weight seasonal forecasts from multiple models of the nmme. In *Climate prediction S&T digest: NWS science & technology infusion climate bulletin supplement*, chapter Climate prediction S&T digest: National Oceanic Atmospheric Administration. Professional Paper.
- Gneiting T., A.E. Raftery, A.H. Westveld III, T. Goldman, 2005: Calibrated probabilistic forecasting using ensemble model output statistics and minimum crps estimation. *Monthly Weather Review* 133, 1098–1118.
- Hartigan J.A., 1975: *Clustering Algorithms (Probability & Mathematical Statistics)*. John Wiley & Sons Inc. Predictores
- Hartigan J.A., M.A. Wong, 1979: Algorithm AS 136: A k-means clustering algorithm". In: *Applied Statistics* 28.1, pp. 100–108.
- Juneng L., F.T. Tangang, 2008: Level and source of predictability of seasonal rainfall anomalies in Malaysia using canonical correlation analysis. *International Journal of Climatology* 28, 1255-1267.
- Kalnay E., M. Kanamitsu, R. Kistler, W. Collins, D. Deaven, L. Gandin, M. Iredell, S. Saha, G. White, J. Woollen, Y. Zhu, A. Leetmaa, B. Reynolds, M. Chelliah, W. Ebisuzaki, W. Higgins, J. Janowiak, K. C. Mo, C. Ropelewski, J. Wang, R. Jenne, D. Joseph, 1996: The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*.
- Kirtman B.P. and Coauthor, 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, <https://doi.org/10.1175/BAMS-D-12-00050.1>.
- Landman W.A., S.J. Mason, 1999: Operational long-lead prediction of South African rainfall using canonical correlation analysis. *International Journal of Climatology* 19, 1073-1090.
- Lim Y., S. Jo, J. Lee, H-S. Oh, H-S. Kang, 2011: An improvement of seasonal climate prediction by regularized canonical correlation analysis. *International Journal of Climatology*. doi: 10.1002/joc.2368.
- Ma H.-Y., S. Xie, S. Klein, K. Williams, J. Boyle, S. Bony, H. Douville, S. Fermepin, B. Medeiros, S. Tyteca, M. Watanabe, D. Williamson, 2014: On the Correspondence between Mean Forecast Errors and Climate Errors in CMIP5 Models, *Journal of Climate* 27, 1781–1798.
- Mason S.J., M.K. Tippett, 2017: Climate Predictability Tool version 15.6.1, Columbia University Academic Commons, <https://doi.org/10.7916/D8SF37S0>.
- Mason S.J., 2018: Guidance on Verification of Operational Seasonal Climate Forecasts. World Meteorological Organization, Commission for Climatology XIV Technical Report.

- Najafi M.R., H. Moradkhani, 2015: Multi-Model Ensemble Analysis of Runoff Extremes for Climate Change Impact Assessments. *Journal of Hydrology* 525(24), 352-361.
- Narapusetty B., D. Collins, R. Murtugudde, J. Gottschalck, C. Peters-Lidard, 2018: Bias correction to improve the skill of summer precipitation forecasts over contiguous United States by the North American Multi-Model Ensemble system. *Atmospheric Science Letters* 19, e818.
- Ou M.H., M. Charles, D.C. Collins, 2016: Sensitivity of calibrated week-2 probabilistic forecast skill to reforecast sampling of the ncep global ensemble forecast system. *Weather and Forecasting* 31(4), 1093-1107.
- Poggi M.M., M.M. Skansi, R. de Elía, 2021: Metodología de verificación del pronóstico estacional por consenso. Nota Técnica SMN 2021-110. Disponible en <http://repositorio.smn.gob.ar/handle/20.500.12160/1724>.
- Reynolds R.W., N.A. Rayner, T.M. Smith, D.C. Stokes, W. Wang, 2002: An Improved In Situ and Satellite SST Analysis for Climate. *J. Climate*, 15, 1609-1625.
- Sachindra D.A., F. Huang, A.F. Barton, B.J.C. Perera, 2013: Least square support vector and multi-linear regression for statistically downscaling general circulation model outputs to catchment streamflows. *International Journal of Climatology* 33, 1087-1106.
- Schepen A., Q.J. Wang, D.E. Robertson, 2014: Seasonal Forecasts of Australian Rainfall through Calibration and Bridging of Coupled GCM Outputs. *Monthly Weather Review* 142(5), 1758-1770.
- Shukla S., D.P. Lettenmaier, 2013: Multi-RCM ensemble downscaling of NCEP CFS winter season forecasts: Implications for seasonal hydrologic forecast skill. *Journal of Geophysical Research: Atmospheres* 10, 770-790.
- Tippett M.K., T. DelSole, S. Mason, A.G. Barnston, 2008: Regression based methods for finding coupled patterns. *Journal of Climate* 21, 4384-4398.
- Unger D.A., H. van den Dool, E. O'Lenic, D. Collins, 2009: Ensemble regression. *Monthly Weather Review* 137(7), 2365-2379.
- Wang Q., D. Robertson, 2011: Multisite probabilistic forecasting of seasonal flows for streams with zero value occurrences. *Water Resources Research* 47, W02546.
- Wang Q.J., D.E. Robertson, F.H.S. Chiew, 2009: A Bayesian joint probability modeling approach for seasonal forecasting of streamflows at multiple sites. *Water Resources Research* 45, W05407.
- Wilks D.S., T.M. Hamill, 2007: Comparison of ensemble-MOS methods using GFS reforecasts. *Monthly Weather Review* 135, 2379-2390.
- WMO, 2019: Manual on the Global Data-processing and Forecasting System. WMO – No. 485. ISBN 978-92-63-10485-4.
- WMO, 2020: Guidance on Operational Practices for Objective Seasonal Forecasting. WMO – No. 1246. ISBN 978-92-63-11246-9.
- Zhang W., G. Villarini, L. Slater, G.A. Vecchi, A.A. Bradley, 2017: Improved ENSO forecasting using Bayesian updating and the North American Multimodel Ensemble (NMME). *Journal of Climate* 30, 9007-9025.

Zhao T., J. Bennett, Q.J. Wang, A. Schepen, A. Wood, D. Robertson, M-H. Ramos, 2017: How suitable is quantile mapping for post-processing GCM precipitation forecasts? *Journal of Climate* 30, 3185-3196.

Instrucciones para publicar Notas Técnicas

En el SMN existieron y existen una importante cantidad de publicaciones periódicas dedicadas a informar a usuarios distintos aspectos de las actividades del servicio, en general asociados con observaciones o pronósticos meteorológicos.

Existe no obstante abundante material escrito de carácter técnico que no tiene un vehículo de comunicación adecuado ya que no se acomoda a las publicaciones arriba mencionadas ni es apropiado para revistas científicas. Este material, sin embargo, es fundamental para plasmar las actividades y desarrollos de la institución y que esta dé cuenta de su producción técnica. Es importante que las actividades de la institución puedan ser comprendidas con solo acercarse a sus diferentes publicaciones y la longitud de los documentos no debe ser un limitante.

Los interesados en transformar sus trabajos en Notas Técnicas pueden comunicarse con Ramón de Elía (rdelia@smn.gov.ar), Luciano Vidal (lvidal@smn.gov.ar) o Martin Rugna (mrugna@smn.gov.ar) de la Dirección Nacional de Ciencia e Innovación en Productos y Servicios, para obtener la plantilla WORD que sirve de modelo para la escritura de la Nota Técnica. Una vez armado el documento deben enviarlo en formato PDF a los correos antes mencionados. Antes del envío final los autores deben informarse del número de serie que le corresponde a su trabajo e incluirlo en la portada.

La versión digital de la Nota Técnica quedará publicada en el Repositorio Digital del Servicio Meteorológico Nacional. Cualquier consulta o duda al respecto, comunicarse con Melisa Acevedo (macevedo@smn.gov.ar).