

PRONÓSTICO ESTADÍSTICO DE AGUA DEL SUELO EN LA REGION PAMPEANA

M. Elizabeth Castañeda ^{1,3}, Marcela H. González ^{1,2}, Liliana B. Spescha ⁴, María Elena Fernández Long ⁴, Alfredo L. Rolla ²

eliza@at.fcen.uba.ar

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

² Centro de Investigaciones del Mar y la Atmósfera. CIMA (CONICET-UBA)

³ Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

⁴ Facultad de Agronomía, Universidad de Buenos Aires (FAUBA)

Palabras clave: reserva de agua del suelo, pronóstico estadístico, forzantes climáticos.

1) INTRODUCCIÓN

Las fluctuaciones climáticas entre años y entre estaciones resultan en una alta variabilidad en la producción de cultivos y pasturas. Es así que las empresas agropecuarias frecuentemente están sujetas a enfrentar circunstancias climáticas adversas que están fuera de su control tales como sequías, excesos hídricos, etc. Un enfoque para encarar circunstancias climáticas adversas consiste en la formulación e implementación de medidas anticipatorias. En este estudio se pretende contribuir a cubrir esa falta a través del desarrollo de herramientas innovadoras basadas en el conocimiento interdisciplinario del agro y el clima. Para ello, se propone una metodología de pronóstico de escenarios de disponibilidad de agua del suelo en la región considerando simultáneamente aspectos causales de la variabilidad climática interanual y la probabilidad de ocurrencia de eventos climáticos.

2) MATERIALES Y MÉTODOS

Se estimó la reserva de agua del suelo (RES) sobre una base de datos mensuales para los meses de octubre, noviembre y diciembre abarcando el período de registro más completo factible (1950-2017), para 34 estaciones meteorológicas localizadas en la región pampeana, utilizando el modelo de Balance Hidrológico Operativo para el Agro (Fernández Long et al., 2012). Este modelo ha demostrado ser capaz de representar la dinámica del agua del suelo (Spennemann, et al., 2020). Se regionalizó el área de estudio explorando con algunos métodos de agrupamiento en busca de aquel que proporciona una clasificación objetiva y estable; la técnica más satisfactoria resultó ser

la introducida por Ward (1963), identificando cuatro regiones o clusters (Figura 1).




Figura 1. Distribución geográfica de las estaciones y los clusters definidos.

Las RESs promediadas sobre cada cluster fueron correlacionadas con distintas variables atmosféricas y de superficie que afectan a la humedad del suelo, obteniéndose predictores. Las variables utilizadas corresponden a valores medios mensuales representadas por los NCEP-

NCAR Reanalysis, (Kalnay *et al.*, 1996). La independencia entre sí de los predictores y su consistencia física se aseguró utilizando la técnica LASSO (Least Absolute Shrinkage and Selection Operator; Tibshirani, 1996). Con los predictores independientes definidos para cada mes y región, se generaron modelos estadísticos utilizando tres metodologías. La más simple fue la regresión lineal múltiple (RLM) con la metodología *backward elimination*. Para considerar la posibilidad de relaciones no lineales, se generaron modelos aditivos generalizados (GAM) (Wood 2006). Además, se utilizó una metodología más sofisticada, la Regresión de Soporte Vectorial (SVR) (James *et al.*, 2013). Se compusieron ensambles con todos aquellos modelos que cumplieron condiciones de eficiencia, determinadas evaluando el error cuadrático medio y el coeficiente de validación cruzada. Se generaron pronósticos categóricos utilizando terciles de RES “observada” que determinaron 3 clases (alta, normal y baja) con los percentiles del 80% y 20%. Se calcularon índices de eficiencia para cada categoría: la probabilidad de detección (POD) y la relación de falsa alarma (FAR) (Wilks 2019). Los porcentajes de aciertos estimados para cada modelo no permiten discernir cuál modelo es el que mejor caracteriza la RES en cada cluster (Figura 2).




Figura 2. Porcentajes de aciertos para los tres modelos: en negro, el modelo obtenido por RLM, en rojo el modelo obtenido con GAM y en azul, el modelo con SVR para octubre (a), noviembre (b) y diciembre (c).

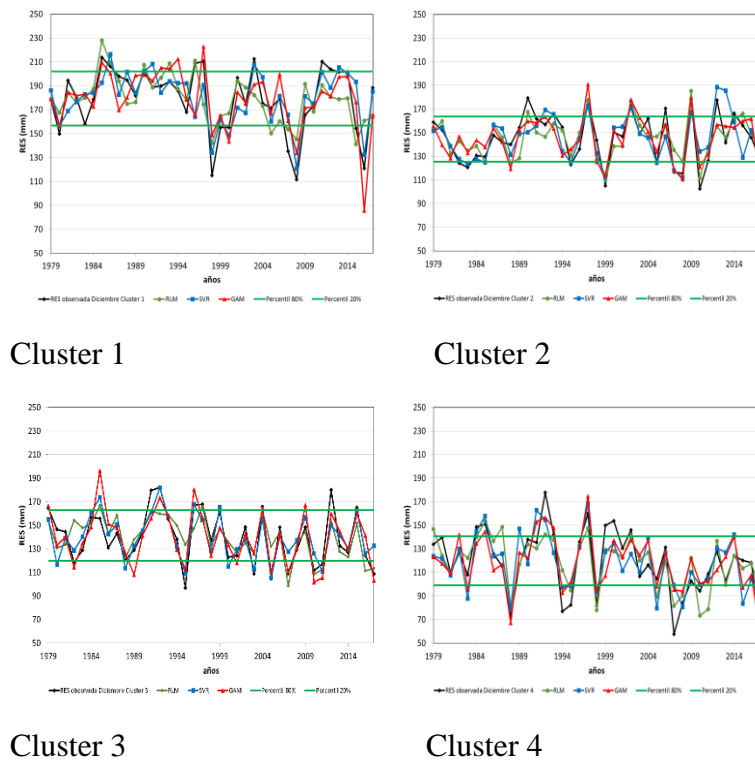


Figura 3. Marcha de la Reserva de agua (RES) estimada por balance hídrico (“observada”), comparada con las obtenidas a partir de tres metodologías: regresión lineal múltiple (RLM), modelos aditivos generalizados (GAM) y regresión de soporte vectorial (SVR), para los cuatro clusters para diciembre.

Para condiciones por encima de la normal la metodología que mejor caracteriza la humedad es el GAM para todos los meses de estudio, en general en todos los clusters, con menos preferencia para el cluster 1. Se presenta, a modo de ejemplo, la performance de los modelos para el mes de diciembre (Figura 3). El menos representativo fue el modelo obtenido a partir de SVR.

3) CONCLUSIONES

Los resultados preliminares presentados en este trabajo permiten pensar que se puede comenzar a resolver un problema concreto para el sector agropecuario en todos los niveles de decisión, que es poder conocer la reserva de agua del suelo (RES) al comienzo de cada campaña agrícola. Este dato es de vital importancia ya que el mismo permite implementar decisiones de manejo; y en mayor medida teniendo en cuenta que en la región pampeana la agricultura que mayoritariamente se realiza es en secano.

Agradecimientos

Proyectos UBACYT 20620170100012BA y UBACYT 20020190100090BA. Al Servicio Meteorológico Nacional por el suministro de los registros meteorológicos.

REFERENCIAS

Fernández Long, M. E.; Spescha, L.; Barnatan, I.; Murphy, G. M. 2012: Modelo de balance hidrológico operativo para el agro (BHOA). *Revista Agronomía & Ambiente* 32(1-2):31-47.

James, G., Witten, D., Hastie, T. y Tibshirani, R., 2013: *An Introduction to Statistical Learning with Applications in R.* Springer.

Kalnay, E., et al., 1996: The NCEP/NCAR 40-year reanalysis project, *Bull. Amer. Meteor. Soc.*, 77, 437-470.

Spennemann, P.C.; Fernández-Long, M.E.; Gattinoni, N.N.; Cammalleri, C. 2020. *Journal of Hydrology : Regional Studies* Soil moisture evaluation over the Argentine Pampas using models , satellite estimations and in-situ measurements. *J. of Hydrology: Regional Studies.* Elsevier, 31: 100723. <https://doi.org/10.1016/j.ejrh.2020.100723>

Tibshirani, R., 1996: Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 58, no. 1, 1996, pp. 267–288.

Ward, J. H., 1963: Hierarchical groupings to optimize an objective function. *Journal of the American Statistical Association*, 58, 236–244.

Wilks, D. S., 2019: *Statistical Methods in the Atmospheric Sciences.* Fourth Edition. Elsevier. ISBN: 9780128158234.

Wood, S., 2006: *Generalized Additive Models: An Introduction with R.* CRC Press. Taylor & Francis. 2nd edition. 474p.