



XXIX Congreso Argentino de la Ciencia del Suelo

Suelos... Huellas del pasado, desafíos del futuro

San Fernando del Valle de Catamarca,
Prov. de Catamarca, Argentina
21 al 24 de mayo de 2024



IDENTIFICACIÓN DE ZONAS AFECTADAS POR SALES EN EL CENTRO SUR DE CÓRDOBA USANDO GOOGLE EARTH ENGINE

Gentili, N.¹, Bocco, J.², Micheloud E.N.^{2,3}, Videla-Mensegue, H.⁴, Córdoba, M.⁵

¹ Instituto Nacional de Tecnología Agropecuaria (INTA), Agencia de Extensión Rural, Córdoba 1405, Corral de Bustos, Córdoba, gentili.nicolas@inta.gob.ar

² Facultad de Ciencias Agrarias (UNL), Kreder 2805, Esperanza, Santa Fe.

³ ICiAgro Litoral (UNL), CONICET, FCA, (UNL), Kreder 2805, Esperanza, Santa Fe.

⁴ INTA, Agencia de Extensión Rural, Castelli 16, Laboulaye, Córdoba.

⁵ Facultad de Ciencias Agropecuarias (UNC), Ing. Agr. Felix Aldo Marrone 746, Córdoba.

RESUMEN:

Los procesos de salinización de los suelos se caracterizan por ser dinámicos y con una elevada variabilidad geográfica afectando en gran medida el desempeño de los cultivos. Las imágenes satelitales tienen un alto potencial para monitorear la variabilidad espaciotemporal de la acumulación de sales. El objetivo de este informe fue desarrollar un modelo que permita predecir la conductividad eléctrica (CE) superficial del suelo de la cuenca hidrográfica del Río Carcarañá, Córdoba, y evaluar su comportamiento a lo largo del tiempo. Se trabajó con dos bases de datos de diferentes años, e imágenes satelitales de la plataforma Google Earth Engine. Con estos se elaboró un modelo de predicción de la salinidad superficial para toda la cuenca, el cual se lo evaluó para los diferentes ciclos de humedad. Se obtuvieron diversos mapas de la cuenca con la predicción de CE, para cada período propuesto. El modelo logró representar adecuadamente la variabilidad espaciotemporal de la CE. Además, esta herramienta permitió dar una idea de los valores de CE que afecta cada zona de la cuenca. Se concluye que, para la cuenca en estudio, fue factible predecir la CE superficial del suelo mediante el uso de sensores remotos y datos referidos al suelo para el período de tiempo estudiado.

PALABRAS CLAVE:

Teledetección – Conductividad Eléctrica – Machine learning.

INTRODUCCIÓN

En la provincia de Córdoba (Argentina), utilizando mapas con escala 1:500.000, Bahill et al. (2003) determinaron que el 14% de la superficie total corresponde a suelos con algún grado de salinidad.

La salinidad de los suelos puede deberse a factores naturales o antropogénicos. Si bien los procesos naturales de salinización ocurren independientemente de las actividades antropogénicas, la agricultura acelera estos procesos (Gorji et al., 2017; Stavi et al., 2021). La salinidad del suelo disminuye la disponibilidad de agua para los cultivos y puede dar lugar a problemas por toxicidad cuando la concentración de los elementos en la solución excede los límites de tolerancia de las plantas (Hammam y Mohamed, 2020).

La salinidad tiene una alta variabilidad espaciotemporal. Es muy importante monitorear y mapear sus cambios para predecir fenómenos naturales y desastres como la desertificación (Gorji et al., 2017). Sin embargo, las técnicas de estudio tradicionales son difíciles y costosas de implementar. En este sentido, las imágenes satelitales poseen un

Organizado por:



elevado potencial para monitorear la variabilidad espaciotemporal de estos suelos (Bocco et al., 2023). Existen numerosos estudios que evaluaron la salinidad del suelo a partir de imágenes satelitales. Por ejemplo, Rafik et al. (2022), evaluaron el incremento de la superficie afectada por salinidad en el período de 1984 a 2018 en una cuenca en el norte de Marruecos. Prajapati et al. (2021) realizaron un trabajo similar en la India. Sin embargo, ninguno de estos trabajos fue realizado en las condiciones agroecológicas de la pampa argentina.

Este trabajo tiene por objetivo desarrollar un modelo que permita predecir la conductividad eléctrica (CE) superficial del suelo de la cuenca hidrográfica del Río Carcarañá, Córdoba, y evaluar su comportamiento a lo largo del tiempo. Se realiza una interpretación de imágenes satelitales en Google Earth Engine, mediante la aplicación de índices de salinidad, índices de vegetación y diferentes variables asociadas al suelo.

MATERIALES Y MÉTODOS

Área de estudio

El área de estudio se centró en la cuenca hidrográfica del Río Carcarañá, limitada dentro de la provincia de Córdoba. La cuenca nace al este de las sierras de Calamuchita, las aguas de las lluvias drenan por sus dos ríos principales: el Río Tercero y el Río Cuarto, que al este de la provincia unen sus trayectos formando el Río Carcarañá (Martínez, 2011).

Dicha cuenca, solamente en Córdoba, comprende un área total de aproximadamente 65.432 Km² (Administración Provincial de Recursos Hídricos, 2024).

En la mayor parte de la cuenca predomina el clima húmedo-subhúmedo, donde las precipitaciones decrecen hacia el oeste. La temperatura media anual se encuentra en 16 °C, las precipitaciones rondan los 700 mm anuales y la estacionalidad es creciente hacia el oeste (Martínez, 2011).

En base a datos de precipitaciones otorgados por el Servicio Meteorológico Nacional (SMN), para el período 2013 - 2023, se definieron ciclos húmedos, neutros y secos para el área bajo estudio (Tabla 1).

Tabla 1: Distribución de las precipitaciones en la cuenca para los años evaluados.

Año	Río Cuarto	Laboulaye	Marcos Juárez	Promedio	Ciclo
2013	768.6	549.8	1014.1	778	Neutro
2014	879.5	1188.3	889.9	986	Neutro
2015	976.1	958.8	1165.6	1034	Húmedo
2016	748.7	1375.4	1106.6	1077	Húmedo
2017	560.9	1090.6	996.0	883	Neutro
2018	651.7	760.5	886.4	766	Neutro
2019	1058.3	670.0	943.9	891	Neutro
2020	539.2	999.0	752.0	763	Neutro
2021	834.3	1068.4	1031.1	978	Neutro
2022	458.1	806.6	547.7	604	Seco
2023			639.0	639	Seco
Prom. 2013-2023	748	947	907	867	
			Desv. Est.	157.24	
			Prom. +1 DE	1024.19	
			Prom. -1 DE	709.71	

Datos de suelo y determinaciones químicas

El modelo de predicción de salinidad fue desarrollado a partir de dos bases de datos. En la primera, las muestras (n=155) se tomaron durante el año 2014, abarcando toda la superficie de la cuenca (Giannini Kurina et al., 2019). La profundidad de muestreo fue de 15 cm, en una cuadrícula regular de aproximadamente 40 x 40 km.

La segunda base de información que se utilizó, son datos provenientes de muestreos realizados en campos de productores de manera particular. Fueron tomados en 2019-2021

conformando 172 muestras. La profundidad de muestreo fue de 20 cm, y con una distribución irregular a lo largo de la superficie de la cuenca (IDECOR y Mapas Córdoba, 2024; Videla Menesegue H., comunicación personal, datos no publicados). Ambas fuentes de información estaban georreferenciadas y contaban con datos de pH, CE, capacidad de intercambio catiónica y porcentaje de sodio de intercambio (Figura 1). Para el desarrollo de este estudio, solo se utilizaron los valores de CE.

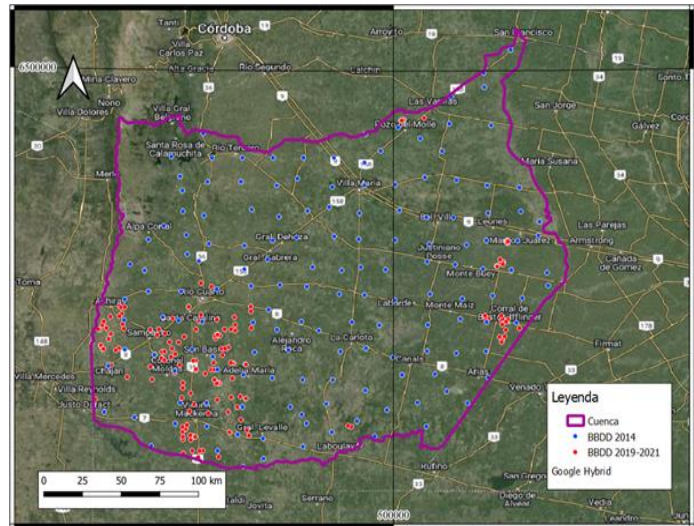


Figura 1: Ubicación del área de estudio y puntos de muestreo georreferenciados.

Procesamiento de imágenes

Se utilizó la plataforma Google Earth Engine (GEE) para procesar todas las imágenes satelitales de la Misión Landsat 8, para cada ciclo de humedad anteriormente definido. A las mismas se les aplicó un filtro de nubosidad, lo cual eliminó aquellas que tuvieran más de un 30% de incidencia de nubes. Una vez obtenida la colección de imágenes para cada período, se le aplicó el cálculo de los diferentes índices de vegetación y salinidad encontrados en la bibliografía consultada (Tabla 2). Además, se incluyeron colecciones de datos texturales y de elevaciones (NASA, 2024; Soil Grids, 2024).

Tabla 2: Índices utilizados, y su adaptación a la Misión satelital Landsat 8.

Abreviación del Índice	M. Satelital	Ecuación adaptada a la M. Landsat 8	Referencias
NDVI		$B5 - B4$ $B5 + B4$	
SAVI		$B5 - B4$ $1.5 \cdot \frac{B5 - B4}{B5 + B4 + 0.5}$	
NDWI		$B3 - B5$ $B3 + B5$	
SI 1	IRS-1B LISS-II	$\sqrt{B2 + B4}$	Khan et al, 2005
SI 2	IRS-1B LISS-II	$B4 - B5$ $B4 + B5$	Khan et al, 2005
SI 3	IRS-1B LISS-II	$\sqrt{B4 + B5}$	Khan et Abbas, 2007
SI 4	IRS-1B LISS-II	$B3 - B4$ $B3 + B4$	Khan et Abbas, 2007
SI 5	ASTER	$B6 - B7$ $B6 + B7$	Khan et Abbas, 2007
SI 7	SPOT2	$\sqrt{B3^2 + B4^2}$	Douaoui et al, 2006
SI 8	Landsat 5- TM	$B5$ $B6$	IDNProject, 2002
SI 9	Landsat 5- TM	$B7 - B5$ $B7 + B5$	IDNProject, 2002
SI 10	EO-1 ALI	$B5 - B6$	Bannari et al, 2008
SI 11	EO-1 ALI	$B5 + B6 - B6 + B6$ $B5$	Bannari et al, 2008
SI 12	IRS-1B LISS-II	$B2$ $B4$	Abbas et al, 2008
SI 13	IRS-1B LISS-II	$B2 - B4$ $B2 + B4$	Abbas et al, 2008
SI14	Spot 2	$\sqrt{B3 + B4}$	Douaoui et al, 2006
SI15	Spot 2	$\sqrt{B3^2 + B4^2 + B5^2}$	Douaoui et al, 2006
SI16	IKONOS	$B4$ $B5 \cdot 100$	Stavi et al, 2021
SI17	IKONOS	$\sqrt{B4^2 + B5^2}$	Stavi et al, 2021
SI18	Landsat 7	$\frac{(B5 + B4) - (B3 + B2)}{\sqrt{(B5 + B4) + (B3 + B2)}}$	Stavi et al, 2021
SI19	Landsat 7	$B6 - B5$ $B6 + B5$	Stavi et al, 2021
SI20	IB4S - 1B	$\sqrt{B4^2 + B5^2}$	Khan et al, 2005
SI21	Landsat 8 oli	$(B1^2 + 50) - (B2 + B3 + B4)$	Stavi et al, 2021
SI22	Sentinel 2	$B6 - B3$ $B3 - B6$	Stavi et al, 2021

Entrenamiento del modelo

El modelo de predicción de CE fue desarrollado con un algoritmo de aprendizaje automático Random Forest (RF). Las bases de datos, de forma individual, se dividieron en forma aleatoria. El 70% de los datos para realizar el entrenamiento del modelo mientras que el 30% restante se utilizó para la validación. El grado de ajuste del modelo se evaluó con los siguientes indicadores estadísticos: raíz del error medio cuadrático (RMSE) y error absoluto medio (MAE).

Además, también se calculó la importancia de las 28 variables utilizadas en el modelo (21 índices de salinidad, tres índices de vegetación y cuatro variables referidas al suelo: textura y elevaciones) para cada situación evaluada. A partir de esto se seleccionaron las diez variables de mayor relevancia en cada caso, y se volvió a entrenar el modelo. De esta manera se evaluó, para los diferentes ciclos (húmedos, secos y neutros) y para las dos bases de datos disponibles, su comportamiento utilizando todas las variables y las diez más relevantes en cada caso.

RESULTADOS Y DISCUSIÓN

En la Figura 2 se observa un ranking de las primeras diez variables más importantes. En las Figuras 3 y 4 se muestra la información que se obtuvo al ejecutar el modelo propuesto. Se observan los valores máximos, mínimos y el promedio de CE de la predicción, y además, los valores de RMSE y MAE para cada situación.




Figura 2: Ranking de frecuencias relativas de las primeras 10 variables más importantes del modelo.

Se destaca que para la base de datos del 2014, al no contar con valores extremos de CE, las predicciones que se obtienen nunca superaron los $2,5 \text{ dS m}^{-1}$, pero, al estar mejor distribuida espacialmente, el error que se obtiene es menor. Para este caso, el período húmedo mostró los valores promedios de CE más elevados. Contrariamente en la base de datos 2019-2021, la predicción demuestra zonas con salinidad ($> 4 \text{ dS m}^{-1}$), pero, por la distribución espacial irregular, el error se eleva para cada situación. En este caso, los períodos neutros y secos son los que mostraron los valores promedios de CE más elevados.




Figura 3: Valores obtenidos por el modelo. para la base de datos 2014.

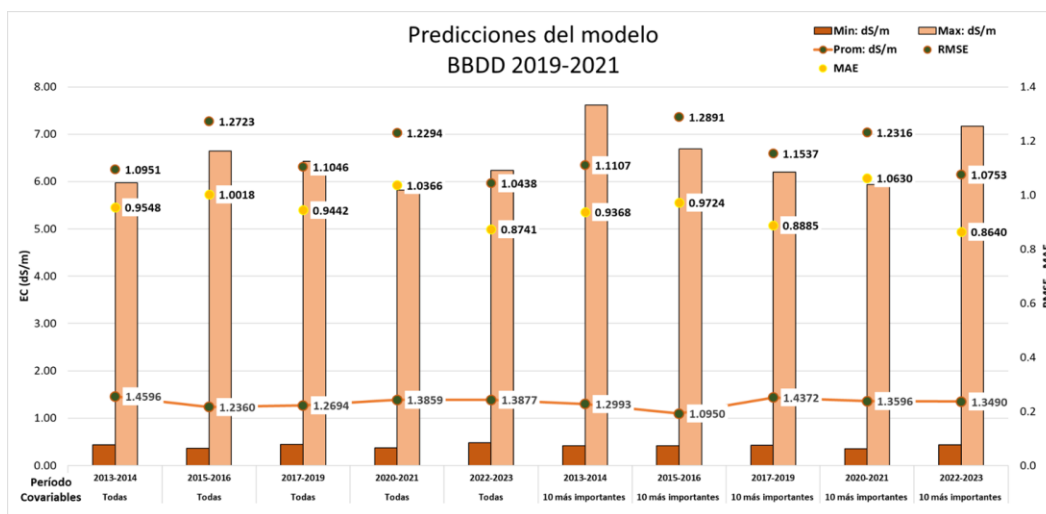


Figura 4: Valores obtenidos por el modelo para la base de datos 2019-2021.

En las Figuras 5 y 6 se observan las predicciones obtenidas a partir de la ejecución del modelo para cada situación. Las predicciones con las 10 variables más importantes en general estiman más superficie con CE elevada que las predicciones con todas las variables. Esto puede deberse a la autocorrelación que puede ocurrir entre las variables. Además se observa mayores superficies con CE elevada cuando se modela sobre la base de información 2019-2021.

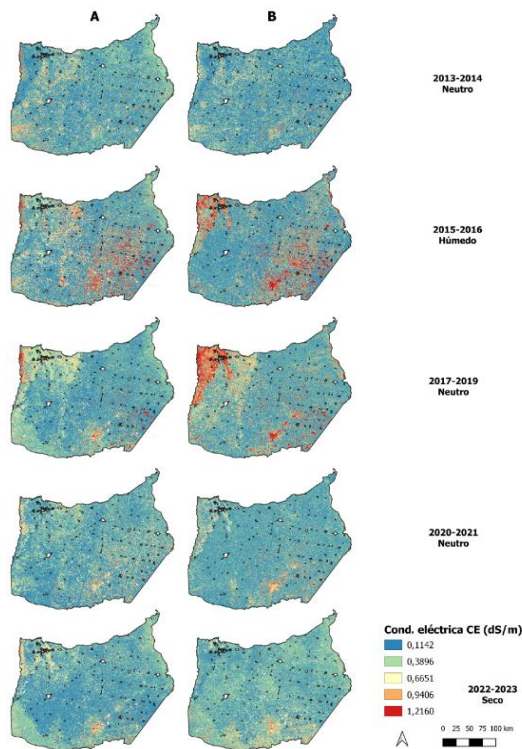


Figura 5: Estimación de la EC para la Cuenca del Río Carcarañá, utilizando la base de datos correspondiente al 2014. (A): Modelo con todas las variables. (B): Modelo con las 10 variables más importantes.

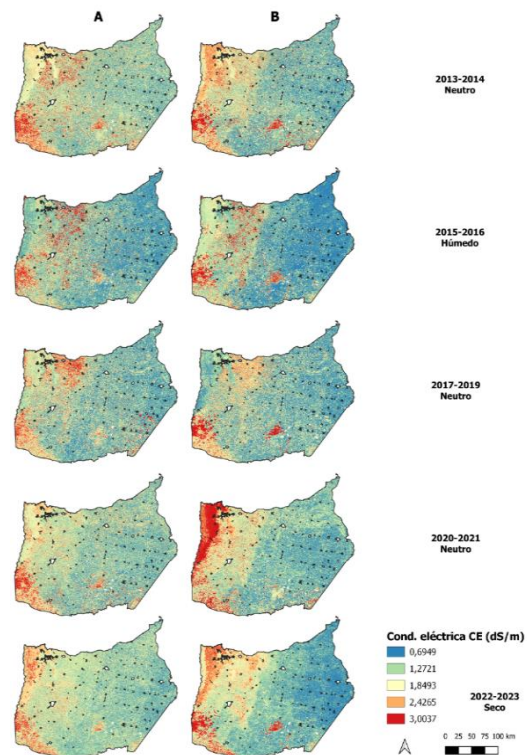


Figura 6: Estimación de la EC para la Cuenca del Río Carcarañá, utilizando la base de datos correspondiente al 2019-2021. (A): Modelo con todas las variables. (B): Modelo con las 10 variables más importantes.

Se seguirá investigando para elevar la precisión del modelo aprovechando las demás capas de información con la que cuentan las bases de datos (CIC, pH, PSI, CO), que pueden generar información adicional y útil para comprender este modelo. Aun así, se observó que la base de datos 2014 fue obtenida con otros fines de caracterización más generales y no para el mapeo específico de la salinidad. En este sentido, la naturaleza de la base de datos 2019-2021 estuvo enfocada en las determinaciones para el diagnóstico de la salinidad, pero su distribución en el espacio dentro de la cuenca estudiada no es aleatoria. Se destaca la posibilidad de agregar nuevas bases de datos que contribuyan a elevar la precisión del modelo, disminuir el error y/o ampliar la superficie a predecir. Otro aspecto para considerar es la evaluación de la autocorrelación que puede haber entre las variables seleccionadas. El uso de un gran conjunto de covariables aumenta la probabilidad de sobreajuste y reduce la interpretabilidad del modelo RF (Sote, C. et al., 2022).

CONCLUSIONES

Se obtuvieron mapas de la cuenca con la predicción de CE para cada período propuesto, logrando representar adecuadamente su variabilidad espaciotemporal. Además, el modelo permitió dar una idea de los valores de CE en distintas zonas de la cuenca.

Se determinaron las variables más importantes para predecir la CE, pudiendo extrapolar el estudio a otras áreas o aumentar la escala de trabajo. No se observaron grandes diferencias entre los valores de CE modelada para cada ciclo climático, lo que sugiere que se podría estudiar de forma más extendida en el tiempo o con otros índices espectrales más relacionados a esta condición.

Por último, se concluye que, para la cuenca en estudio, fue factible predecir la CE superficial del suelo mediante el uso de sensores remotos y datos referidos al suelo para el período de tiempo estudiado.

REFERENCIAS

- Administración Provincial de Recursos Hídricos. (2024). *Sistema de información de Recursos Hídricos*. <https://Experience.Arcgis.Com/Experience/527c1a6f6dcf479eab2aec4c31b6877a?Org=APRHI>.
- Bocco, Joaquin., Micheloud, E. N., & Marano, R. P. (2023). *IDENTIFICACIÓN DE POSIBLES ZONAS AFECTADAS POR SALINIZACIÓN DE SUELOS CON ÍNDICES ESPECTRALES EN GOOGLE ENGINE*.
- Giannini Kurina, F., Hang, S., Macchiavelli, R., & Balzarini, M. (2019). *Spatial predictive modelling essential to assess the environmental impacts of herbicides*. <https://doi.org/10.1016/j.geoderma.2019.07.032>
- Gorji, T., Sertel, E., & Tanik, A. (2017). Monitoring soil salinity via remote sensing technology under data scarce conditions: A case study from Turkey. *Ecological Indicators*, 74, 384–391. <https://doi.org/10.1016/j.ecolind.2016.11.043>
- Hammam, A. A., & Mohamed, E. S. (2020). Mapping soil salinity in the East Nile Delta using several methodological approaches of salinity assessment. *Egyptian Journal of Remote Sensing and Space Science*, 23(2), 125–131. <https://doi.org/10.1016/j.ejrs.2018.11.002>
- IDECOR, & Mapas Córdoba. (2024, April 24). *Cartas de suelo*. Carta de Suelo - Río Cuarto.
- Martinez, S. J. (2011). *CUENCA DEL RÍO CARCARAÑÁ*.
- NASA. (2024, April 24). *Earth Data*. <https://www.earthdata.nasa.gov/sensors/srtm>
- Soil Grids. (2024, April 24). *Soil Grids*. Global Soil Grids. <https://soilgrids.org/>
- Sothe, C., Gonsamo, A., Arabian, J., & Snider, J. (2022). Large scale mapping of soil organic carbon concentration with 3D machine learning and satellite observations. *Geoderma*, 405, 115402.
- Stavi, I., Thevs, N., & Priori, S. (2021). Soil Salinity and Sodicity in Drylands: A Review of Causes, Effects, Monitoring, and Restoration Measures. In *Frontiers in Environmental Science* (Vol. 9). Frontiers Media S.A. <https://doi.org/10.3389/fenvs.2021.712831>