

A landscape photograph of a high-altitude valley. In the foreground, there is a rocky, gravelly slope. A small stream flows through the middle ground, leading to a larger turquoise lake. The background features rugged mountains with distinct reddish-brown and greyish-brown hues under a clear blue sky.

# Distribución de humedales en la República Argentina

Informe técnico

Instituto Nacional de  
Tecnología Agropecuaria  
Argentina





**El presente trabajo fue realizado en el marco del Proyecto Nacional de INTA: “*Humedales de la República Argentina: distribución, usos y recomendaciones coparticipativas para una producción sostenible (PD 1506)*” (2019-2022)**

### **Autores**

María Fabiana Navarro (Coordinadora)

Carlos S. Navarro (EEA Reconquista)	Alejandro Pezzola (EEA Ascasubi)
Raúl Barrios (EEA Corrientes)	Fernando Umaña (EEA Bariloche)
Noelia Calamari (EEA Paraná)	Claudia Vidal (EEA Reconquista)
Victorio Dieta (AER Delta Frontal)	Cristina Winschel (EEA Ascasubi)
Guillermo García Martínez (EEA Esquel)	Silvina Albarracin Franco (EEA Cerro Azul)
María d. Rosario Iturralde Elortegui (EEA Balcarce)	Fernando Alvarenga (EEA Cerro Azul)
Ditmar B. Kurtz (EEA Corrientes)	Santiago Behr (EEA Chubut)
Nicole J. Michard (Inst. Recursos Biológicos)	María Victoria Cremona (EEA Bariloche)
Paula Paredes (EEA Santa Cruz)	Gregorio Gavier Pizarro (Inst. R. Biológicos)
Griselda Saucedo (EEA Corrientes)	María Jesús Mosciaro (EEA Salta)
Silvina Alday (EEA San Juan)	Ruth Perucca (EEA Corrientes)
Francisco Cianfagna (CONICET – IPAF NOA)	María Gabriela Sepulcri (AER Luján)
Matías Curcio (EEA Esquel)	Víctor Utrilla (EEA Santa Cruz)
Andrea Enríquez (EEA Bariloche)	Juan Pablo Zamora Gómez (IPAF NOA)
Astor López (EEA Saenz Peña)	Enrique Livraghi (AER Ushuaia)
Federico Miranda (AER Formosa)	Yanina Sica

### **Citar**

Navarro, MF., Navarro, CS., Barrios, R., Calamari, N., Dieta, V., García Martínez, G., Iturralde Elortegui, MR., Kurtz, DB., Michard, NJ., Paredes, P., Saucedo, G., Alday, S., Cianfagna, F., Curcio, M., Enriquez, A., Lopez, A., Miranda, F., Pezzola, A., Umaña, F., Vidal, C., Winschel, C., Albarracín Franco, S., Alvarenga, F., Behr, S., Cremona, M.F., Gavier Pizarro, G., Mosciaro, MJ., Perucca, R., Sepulcri, MG., Utrilla, V., Zamora Gomez, JP, Livraghi, E., Sica, Y. 2022. Mapa de distribución potencial de humedales en Argentina. Informe técnico. Instituto Nacional de Tecnología Agropecuaria.

**Septiembre 2022**



## INDICE

<b>RESUMEN</b> .....	<b>1</b>
<b>1. INTRODUCCIÓN</b> .....	<b>2</b>
<b>2. MARCO CONCEPTUAL Y LINEAMIENTOS METODOLÓGICOS</b> .....	<b>4</b>
2.1    Definiciones.....	4
2.2.1    Humedal .....	4
2.1.2    Suelo hídrico.....	5
2.1.3    Sustrato no suelo.....	5
2.2    Área de estudio .....	5
2.3    Aproximación metodológica .....	6
2.3.1    Datos .....	7
2.3.1.1 Datos de referencia.....	8
2.3.1.2 Datos de sensores remotos.....	10
2.3.1.3 Datos topográficos .....	11
2.3.2    Selección del modelo y determinación espacial de humedales.....	12
2.3.3    Evaluación de la exactitud de la determinación de los humedales .....	13
<b>3. RESULTADOS y DISCUSIÓN</b> .....	<b>16</b>
<b>4. CONSIDERACIONES FINALES</b> .....	<b>25</b>
<b>5. CONCLUSIONES</b> .....	<b>27</b>
<b>6. AGRADECIMIENTOS</b> .....	<b>28</b>
<b>7. REFERENCIAS</b> .....	<b>28</b>
<b>ANEXO I</b> .....	<b>33</b>
<b>ANEXO II</b> .....	<b>34</b>
<b>ANEXO III – SCRIPT en GEE para determinación humedales en Argentina</b> .....	<b>34</b>
<b>ANEXO IV</b> .....	<b>41</b>
<b>ANEXO V</b> .....	<b>43</b>
<b>ANEXO VI - MAPAS</b> .....	<b>44</b>



## RESUMEN

Los humedales, que representan aproximadamente el 7% de la superficie de la tierra (Ramsar, 2018) se encuentran entre los ecosistemas más valiosos no sólo en términos socioeconómico-productivos, sino también ambientales, dada su importancia en la provisión de servicios ecosistémicos y biodiversidad. La extensión de humedales naturales viene disminuyendo en todo el mundo y cada vez con mayor celeridad. El crecimiento poblacional previsto para las próximas décadas generará un incremento en la demanda de servicios ecosistémicos provenientes de estos socio-agroecosistemas, con lo cual el maximizar oportunidades productivas y al mismo tiempo minimizar potenciales impactos ambientales y sociales negativos, constituye el gran desafío para los tomadores de decisión. Esto requiere del análisis, aplicación y evaluación de herramientas y tecnologías que contribuyan a la gestión sostenible de los humedales. En los últimos años, el incremento de flujos de datos satelitales de libre acceso, el surgimiento de la computación en la nube y el creciente uso de algoritmos de aprendizaje automatizado han facilitado la integración y procesamiento de grandes volúmenes de datos permitiendo acortar tiempos y mejorar productos cartográficos. En Argentina son escasos los trabajos de abordaje a nivel nacional en relación a la ubicación de los humedales en el territorio nacional. El objetivo de nuestro trabajo fue, por un lado, generar un mapa actualizado de la probabilidad de ocurrencia y distribución de humedales en todo el país a partir de un análisis multitemporal de 20 años de imágenes satelitales, así como desarrollar un marco metodológico que permita establecer dicha ocurrencia en todo el territorio nacional, a través de una plataforma de fácil acceso y de fuente abierta. Para esto, se procesó 26.000 sitios de entrenamiento, 54720 imágenes satelitales de los sensores Landsat 5 y 8 y el Modelo Digital de Elevaciones de Argentina (MDE\_Ar), a partir de los cuales se derivaron 43 variables predictoras, se aplicó el algoritmo Random Forest (RF) dentro del Google Earth Engine (GEE). El mapa resultante presenta una muy buena precisión en términos de análisis de campo, visual y estadístico, teniendo en cuenta la gran superficie del país (2,78 millones km<sup>2</sup>). La exactitud global de la determinación fue del **89%**, mientras que la exactitud del productor y usuario (especificidad y precisión, respectivamente) para la clase humedal fue, en ambos casos, del **94%**. Basándonos en el mapa final de determinación, estimamos que el **9,5%** (265.200 km<sup>2</sup>) de Argentina está cubierto por humedales.



## 1. INTRODUCCIÓN

Todos los procesos de la vida dependen del agua: desde el crecimiento de las plantas y los ciclos reproductivos de algunos animales hasta la subsistencia humana. Los humedales son, por lo tanto, parte de un delicado equilibrio ambiental y conforman una compleja estructura en la que los seres humanos cumplimos un rol importante. Conocer la presencia de estos ecosistemas, entender su funcionamiento y tomar conciencia de los ciclos de vida asociados con ellos son los primeros pasos para gestionarlos sin alterar su funcionamiento (Jaramillo Villa et al. 2015)

De acuerdo a la Convención Relativa a los Humedales de Importancia Internacional (Convención Ramsar), celebrada en la ciudad de Ramsar (Irán) en 1971, los humedales son ecosistemas en los que el agua es el principal factor que controla el entorno y la vida vegetal y animal asociada al mismo; donde la capa freática se halla en la superficie terrestre o cerca de ella o donde la tierra está cubierta por aguas, sean éstas de régimen natural o artificial, permanentes o temporales, estancadas o corrientes, dulces o saladas, incluidas las extensiones de agua marina cuya profundidad en marea baja no exceda de seis metros.

Los humedales, que representan aproximadamente el 7% de la superficie de la tierra (Ramsar, 2018) e incluyen bañados y esteros, vegas y mallines, pastizales inundables y/o anegables, turberas, bosques fluviales, zonas costeras estuarinas y marinas, entre otros, se encuentran entre los ecosistemas más valiosos no sólo en términos socioeconómico-productivos, sino también ambientales, dada su importancia en la provisión de servicios ecosistémicos y biodiversidad (Zedler 2003; Mitsch & Gossilink 2007). Almacenan, absorben y purifican agua, constituyendo una de las principales fuentes de abastecimiento de agua dulce y contribuyendo con la recarga y descarga de acuíferos (Marton et al. 2015). Asimismo, proporcionan alimentos, fibra y combustible (Ramsar 2018), constituyen hábitats de una gran diversidad de especies de vida silvestre y son considerados grandes amortiguadores de excedentes hídricos (Kingsford et al. 2016). Tienen un papel fundamental en los ciclos biogeoquímicos (es decir, en el movimiento de elementos esenciales entre los organismos vivos y las distintas esferas ambientales), reteniendo, almacenando y transportando nutrientes y sedimentos, y constituyen importantes sumideros de carbono (Fisher et al. 2004; Ward et al. 2010). En síntesis, los humedales son clave para los seres humanos y toda vida en el planeta, contribuyendo con servicios de aprovisionamiento, regulación, soporte y culturales (Ramsar 2018).

La extensión de humedales naturales viene disminuyendo en todo el mundo y cada vez con mayor celeridad (Millennium Ecosystem Assessment 2005). Más de la mitad de los humedales, a nivel global, han sido degradados o eliminados en los últimos 150 años (Gardner et al. 2015), debido fundamentalmente a la sobreexplotación de recursos, drenaje o reconversión para actividades agropecuarias y urbanísticas (Van Asselen et al. 2013) y al efecto del cambio climático (Junk et al. 2013). Estos impactos, que no son ajenos a lo que

ocurre en los humedales de Argentina, traen aparejado la disminución de sus capacidades, de sus funciones ecológicas, de sus hábitats y de su diversidad biológica (Keddy 2010; Quesnelle et al. 2013).

Según el último reporte del Departamento de Asuntos Económicos y Sociales de la Organización de las Naciones Unidas (World Population Prospects - ONU 2022), la población humana mundial es actualmente tres veces mayor a la existente a mediados del siglo pasado y según proyecciones, se estima que alcance los 8.5 billones en el 2030 y 9.7 billones en el 2050. En vista de esto, la demanda de servicios ecosistémicos provenientes de humedales continuará en incremento, con lo cual el maximizar oportunidades productivas y al mismo tiempo minimizar potenciales impactos ambientales y sociales negativos, constituye el gran desafío para tomadores de decisión. Además, la comprensión de los servicios que prestan los humedales se ve actualmente limitada por los relativamente escasos conocimientos sobre su distribución, extensión, variabilidad interanual de las inundaciones y estado. Esto requiere del análisis, aplicación y evaluación de herramientas y tecnologías que contribuyan a la gestión sostenible de los humedales.

En los últimos años, el incremento de flujos de datos satelitales de libre acceso, el surgimiento de la computación en la nube y el creciente uso de algoritmos de aprendizaje automatizado han facilitado sustancialmente el acceso a datos geoespaciales y modificado la forma en que se utilizan en cartografía. Actualmente, no solo se dispone de mayores volúmenes de datos satelitales, sino que la integración y procesamiento de diversos conjuntos de datos de gran volumen es posible con mucha mayor facilidad, abriendo el espectro al abordaje de nuevas escalas espacio-temporales, lo que hasta hace poco tiempo era inviable en la mayoría de los casos.

Dada la dinámica propia de los humedales, su clasificación ha presentado múltiples dificultades (Meixler y Bain 2010), debido a que la mayoría de los modelos aplicados simplifican los gradientes ambientales reales a la dicotomía de presencia o ausencia de humedales, siendo escasos los trabajos que aplicaron modelos probabilísticos, basados en series temporales, para su determinación (Humphreys et al. 2017). En nuestro país, si bien hay trabajos a escalas zonales o regionales, no existen mapas o inventarios precisos de la ubicación de los humedales a nivel nacional. Kandus et al. (2008) elaboraron, a partir de la Carta de Suelos de la República Argentina (INTA 1995), un mapa indicando potenciales áreas de presencia de humedales y estimaron la superficie ocupada por humedales en 600000 km<sup>2</sup>, lo que equivale al 21,5% de la superficie del país. Por otro lado, Godagnone et al. (2016) elaboraron también un mapa de humedales a partir del mapa Suelos de Argentina (2002), pero restringiendo el análisis a la potencial presencia de suelos hídricos. En este caso, los autores estimaron que la potencial área de ocupación de humedales comprendería el 12% de la superficie del país.

En vista de esto, el presente trabajo tuvo dos objetivos:

1. Generar un mapa actualizado y preciso de la presencia y distribución de humedales en todo el país.
2. Desarrollar un marco metodológico que permita establecer la presencia de humedales en Argentina a través de una plataforma de fácil acceso y de fuente abierta.

Consideramos éste el paso inicial de un proceso tendiente a contribuir a la planificación estratégica del manejo de los recursos naturales, al ordenamiento territorial, así como a la formulación de políticas públicas orientadas a conciliar la producción con la conservación en los humedales.

## **2. MARCO CONCEPTUAL Y LINEAMIENTOS METODOLÓGICOS**

### **2.1 Definiciones**

#### **2.2.1 Humedal**

Como señalan diversos autores (Corwardin et al. 1979; Kandus y Minotti 2018) no existe una definición única e indiscutible para los humedales. Esto se debe principalmente a la gran diversidad estructural y particularidades que presentan estos ecosistemas, pudiendo ser bosques, pastizales, praderas, salares o cuerpos de agua libre.

A partir de la definición establecida en la Convención Ramsar, surgieron otras definiciones propuestas por diferentes países y según propósitos u objetivos también diferentes. Entre ellas, se pueden mencionar la del Programa Biológico Internacional (Westlake et al., 1988), del Servicio de Pesquería y Vida Silvestre de Estados Unidos (USFWS; Corwardin 1979), de Golpal et al. (1990) como base para el inventario de humedales en India, o la propuesta por el Ministerio de Ambiente de España (1999). Algunas de estas definiciones tienen un carácter genérico e incluyen un amplio espectro de ambientes, como la del Convenio Ramsar. Otras, tienen un carácter más científico o técnico, con objetivos más precisos de delimitación de los humedales. Sin embargo, todas, de una u otra forma, enfatizan tres atributos clave: 1) la hidrología (especialmente el grado de inundación o saturación del suelo o sustrato); 2) la biota adaptada (especialmente vegetación hidrófila); y 3) suelos hídricos.

En Argentina, si bien por Ley 23.919 de abril de 1991 se ratificó la Convención Ramsar y por ende su definición, como base para la elaboración del Inventario Nacional de Humedales se acordó una definición operativa en el Taller “Hacia un Inventario Nacional de Humedales”, organizado por la Secretaría de Ambiente y Desarrollo Sustentable de la Nación en setiembre de 2016. Según esta definición, la cual consideramos para el presente trabajo, “humedal es



un ambiente en el cual la presencia temporaria o permanente de agua superficial o subsuperficial causa flujos biogeoquímicos propios y diferentes a los ambientes terrestres y acuáticos. Rasgos distintivos son la presencia de biota adaptada a estas condiciones, comúnmente plantas hidrófitas, y/o suelos hídricos o sustratos con rasgos de hidromorfismo”. Es importante aclarar que los sustratos a los que hace referencia esta definición no son suelos.

### **2.1.2 Suelo hídrico**

Según el Servicio de Conservación de Recursos Naturales del Departamento de Agricultura de los Estados Unidos (USDA 1994) un suelo hídrico es “aquel que se formó bajo condiciones de saturación, inundación o anegamiento el tiempo suficiente durante la estación de crecimiento (de la vegetación) como para desarrollar condiciones anaeróbicas en su parte superior.” Los indicadores morfológicos para reconocer suelos hídricos se agrupan de acuerdo a la textura y considerando el espesor de las capas de suelo, el color, el olor y/o la presencia de otros rasgos de óxido-reducción (hidromorfía de suelo) según la profundidad, cantidad y facilidad con que se distinguen (manchas y masas).

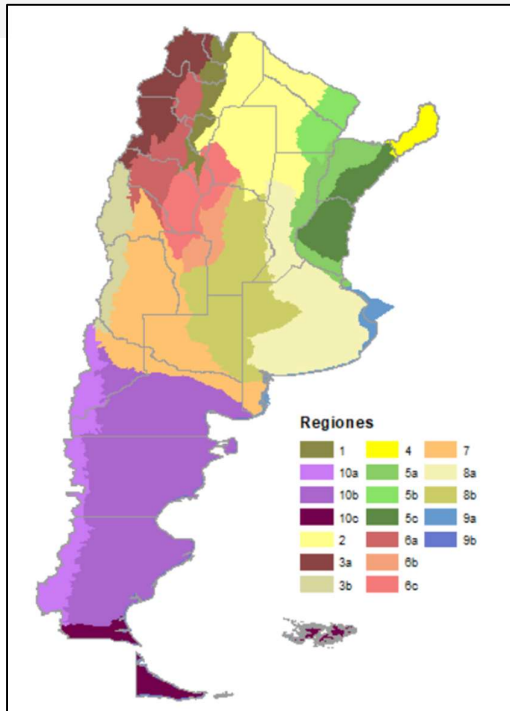
### **2.1.3 Sustrato no suelo**

Se considera sustrato que no es suelo a la parte superior de la corteza terrestre compuesta por sólidos (minerales y materia orgánica), líquidos y gases que no ha sufrido proceso pedogenético, es decir, no ha sido influenciado significativamente por los factores formadores que, interactuando entre sí generan el suelo (material parental, clima, relieve, biota y tiempo), pero aun así puede proporcionar soporte estructural. Ejemplos de esto son: depósitos de sedimentos no consolidados, marismas de marea, afloramientos rocosos, playas y bancos de arena, salinas (Tiner 1999).

## **2.2 Área de estudio**

El presente trabajo fue conducido a nivel de toda la República Argentina, abarcando un área de 2.8 millones km<sup>2</sup>, extendiéndose desde el Océano Atlántico en el este hasta la Cordillera de los Andes en el oeste. Argentina posee diferentes climas a lo largo y ancho de toda su extensión, desde subantárticos en el extremo sur hasta cálidos subtropicales en el extremo norte y húmedos en el extremo oriental a áridos en el occidental. La mayor parte del territorio argentino está cubierto por pastizales, praderas, estepas de gramíneas y estepas mixtas, bosques y tierras de cultivos y humedales, aunque el número y tipo de estos varía dentro de las diferentes regiones del país. La variabilidad inter e intraanual de los humedales,

particularmente respecto al tamaño, extensión y conexión hidrológica local, está dominada mayormente por el momento y la cantidad de precipitación estacional, las variaciones meteorológicas anuales y los cambios climáticos a más largo plazo (Hird et al. 2017geo). Por estas particularidades, para la determinación espacial de los humedales se siguió la división en regiones y subregiones propuesta por Benzaquen et al. (2017; Figura 1)



*Figura 1: Regiones y subregiones definidas para la determinación espacial de humedales: '1: Región Humedales Montanos Precordilleranos y Subandinos'; '2: Región Humedales del Chaco'; '3a:Subregión Vegas Lagunas Salares Puna'; '3b: Subregión Vegas Lagunas Altoandinas'; '4: Región Humedales Misioneros'; '5a: Subregión Ríos Esteros Bañados Lagunas Río Paraná'; '5b: Subregión Riachos Esteros Bañados Chaco Húmedo'; '5c: Subregión Malezles Tembladerles Arroyos Litoraleños'; '6a': Subregión Rios Arroyos Valles Intermontanos'; '6b: Subregión Arroyos Mallines Sierras Centrales'; '6c: Subregión Saalinas Depresión Central'; '7: Región Humedales del Monte Central'; '8a: Subregión Lagunas Pampa Húmeda'; '8b: Subregión Lagunas Salobres Pampa Interior'; '9a: Subregión Playas Marismas Costa Bonaerense'; '9b: Subregión Playa Marismas Costa Patagonia'; '10a: Subregión Lagos Cursos Agua Mallines'; '10b: Subregión Lagunas Vegas Patagonia'; '10c: Subregión Mallines Turberas Patagonia Sur' (fuente: Benzaquen et al.; 2017)*

### 2.3 Aproximación metodológica

Dado que el objetivo de este trabajo fue determinar la ubicación y extensión de los humedales en Argentina, no fueron determinadas ni cuantificadas otras coberturas del suelo, estableciendo una clase correspondiente a humedales, por un lado, y agrupando el resto como no humedales, por otro lado. Los humedales son sistemas espacial-y temporalmente dinámicos que experimentan ciclos de fases húmedas y secas a escala estacional, anual y decadal. Esta variación en la oferta hídrica, así como otros factores que interactúan entre sí (tipo de humedal, geomorfología, suelo, vegetación, clima, tiempo y usos circundantes) determina la existencia de un gradiente o variación espacio-temporal (elasticidad) desde los bordes del humedal, donde la presencia de agua es más efímera, hasta el centro del mismo donde el agua puede ser permanente. Por esta razón, se siguió un enfoque probabilístico a fin de predecir la probabilidad de que cada lugar sea un humedal, basándose en la presencia de agua superficial, en la vegetación, a través del análisis de series temporales de la fenología de la vegetación y características hidrogeomorfológicas, a través de datos topográficos. Este

enfoque incluyó el preprocesamiento de datos satelitales, la definición de las características óptimas de clasificación, la clasificación de ambas clases y la evaluación de la exactitud de la clasificación (Figura 2). Este proceso se realizó en la plataforma de código abierto y acceso libre Google Earth Engine (GEE, Gorelick et al. 2017).

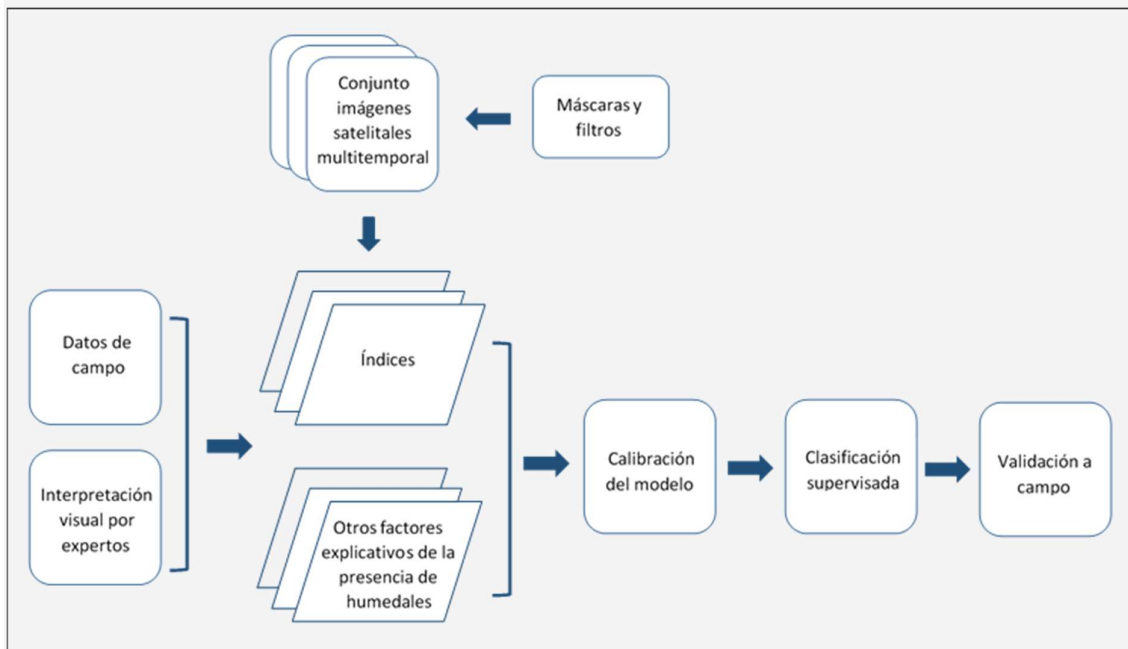


Figura 2. Esquema general de la aproximación metodológica seguida.

### 2.3.1 Datos

Para la determinación y obtención de un mapa preciso de humedales es importante hacer uso de variables óptimas. Sobre la base de estudios anteriores (Hird et al. 2017, Berhane et al. 2018, Amani et al. 2019a y 2019b, Mahdianpari et al. 2019), las variables derivadas de sensores ópticos y de modelos de elevación, listadas en la Tabla 1, tienen el mayor potencial para discriminar diversos tipos de humedales y, por lo tanto, utilizamos en este estudio. Además, incorporamos al análisis datos vectoriales, tanto en el proceso de obtención de las muestras de entrenamiento como en la generación de máscaras utilizadas en el proceso de clasificación. Accedimos a un total de 54720 imágenes satelitales para todo el país y se procesaron en el entorno GEE. En las siguientes secciones se ofrecen más detalles.

Tabla 1. Lista y descripción del conjunto de datos y las variables derivadas de los mismos.

Conjunto de Datos	Descripción	Variables derivadas
MDE 30 m	Modelo digital de elevación (MDE-Ar v2.0) desarrollado por IGN a partir de combinar datos de las misiones SRTM y ALOS	Índice de Posición Topográfica (TPI)





Índice de Humedad Topográfica  
(TWI)

Imágenes ópticas	54720 imágenes satelitales de los sensores Landsat 5 y Landsat 8 de un período de 20 años (2000-2020)	NDVI, SAVI, MNDWI1, MNDWI2, NDWI1, NDWI2, bandas espectrales (Azul, Verde, Roja, IR, SWIR1, SWIR2) y relación entre bandas R35
Mapa global de superficie con agua	Conjunto de datos conteniendo ubicación y distribución temporal de aguas superficiales a nivel mundial, desde 1984 a 2020 (Pekel et al. 2016)	Se utilizaron las bandas originales (ocurrencia, recurrencia y estacionalidad)
Datos auxiliares	Datos vectoriales de: cuerpos de agua continental de todo el país y de cursos de agua permanentes y transitorios; urbanizaciones <a href="https://www.ign.gob.ar/NuestrasActividades/InformacionGeoespacial/CapasSIG">https://www.ign.gob.ar/NuestrasActividades/InformacionGeoespacial/CapasSIG</a>	

### 2.3.1.1 Datos de referencia

Los datos de referencia del terreno, así como su número, desempeñan un papel fundamental en la clasificación supervisada de imágenes satelitales. Para la obtención de los datos de referencia, aplicamos un diseño de muestreo estratificado con base en estimaciones preliminares de humedales, mediante la generación de un búfer de 100 m sobre las capas de ríos, arroyos y cuerpos de agua de IGN (2015), definiendo previamente el 30% de los puntos distribuidos aleatoriamente en estos polígonos con los búferes y el 70% restante distribuidos en el resto del área. Asimismo, generamos una máscara con las áreas urbanas a la que también se le aplicó un búfer de radio variable acorde a la superficie total de éstas (Anexo I), la que aplicamos a cada Región y Subregión y finalmente estimamos el número de puntos acorde a la superficie del área restante. Para estandarizar el número de datos de referencia en todas las regiones, generamos un punto cada 100 km<sup>2</sup> con una distancia mínima de 1 km entre cada punto, acorde a la superficie de cada región. En total generamos 26000 puntos de referencia para todo el país. Posteriormente utilizamos la herramienta Collect Earth (Bey et al. 2016) incluida en la plataforma Open Foris<sup>1</sup> para recopilar información sobre todas las coberturas del suelo en los puntos de referencia, definidos aleatoriamente según el paso previo. A través de Collect Earth, el cual geosincroniza la visualización y el uso de imágenes satelitales de distintas resoluciones espaciales y temporales en el entorno de Google Earth<sup>2</sup>, Bing Maps<sup>3</sup> y Google Earth Engine<sup>4</sup>, realizamos el análisis e interpretación visual de imágenes de alta resolución e índices de vegetación (NDVI). Para ello, mediante Collect Earth, diseñamos una plantilla y completamos una encuesta estructurada para cada punto de muestreo con

<sup>1</sup> <https://openforis.org/>

<sup>2</sup> <http://www.gearthblog.com/blog/archives/2015/09/google-earth-imagery-suppliers.html>

<sup>3</sup> <http://blogs.bing.com/maps/2011/06/27/bing-maps-unveils-exclusive-high-res-imagery-withglobal-ortho-project/>

<sup>4</sup> <https://earthengine.google.com/datasets/>

información relevante sobre la cobertura del suelo basada en la interpretación visual (Anexo II). Para el análisis muestral generamos parcelas de 0.50 ha con una grilla de 5x5 puntos por parcela, con un período de análisis de 20 años (Figura 3). El análisis incluyó la determinación de la pureza de la muestra (un único tipo de cobertura), la estabilidad (la cobertura no sufrió cambios en el período de 20 años) y la confiabilidad (certeza en la definición del tipo de cobertura). Finalmente obtuvimos 17200 datos de referencia (Figura 4), los cuales fueron divididos de forma aleatoria en un conjunto de datos de entrenamiento compuesto por el 70% de los datos de referencia y un conjunto de datos de prueba del algoritmo con el 30% restante.

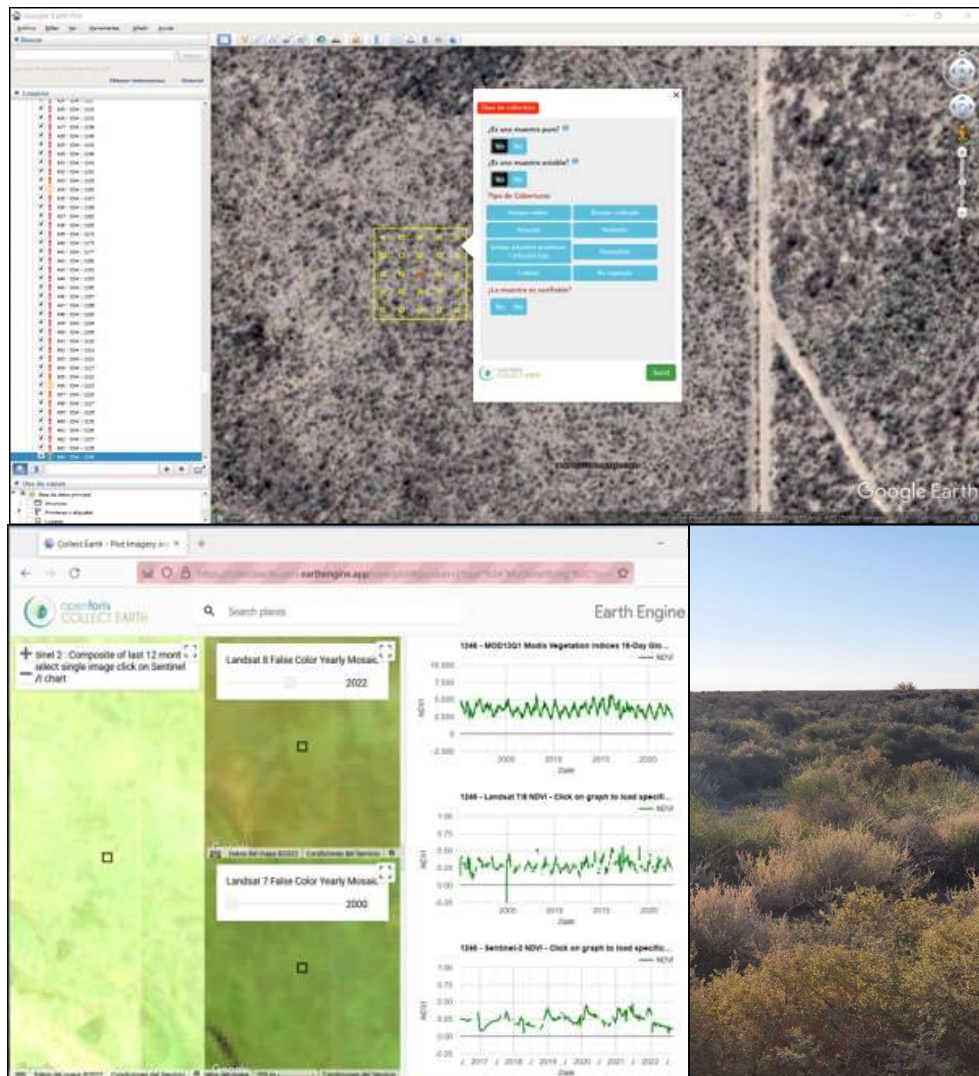
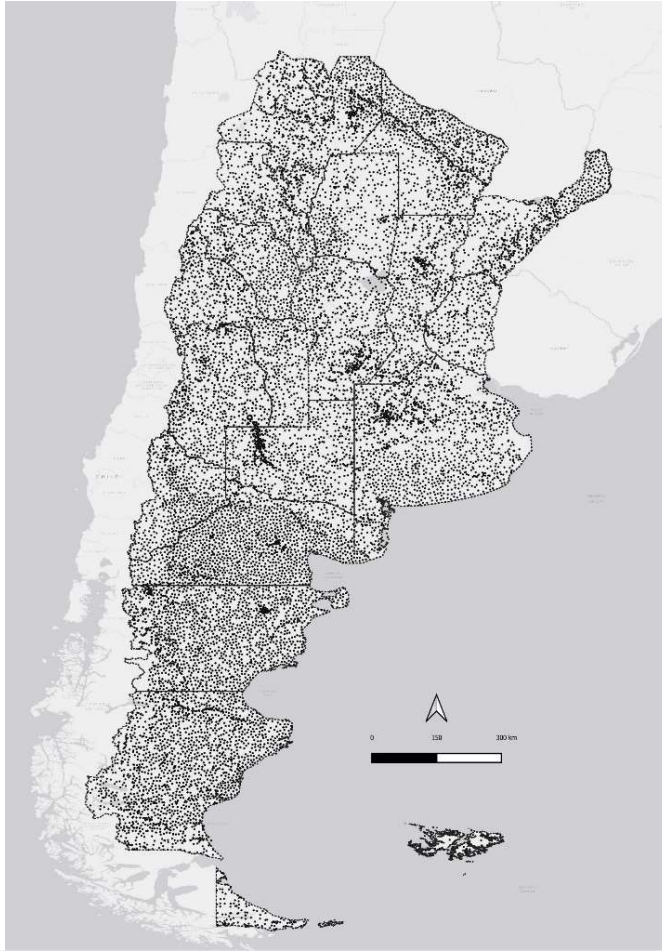


Figura 3. Ilustración de un diseño de muestreo. Plantilla con la encuesta de coberturas del suelo (arriba); análisis de las curvas de NDVI de la parcela (abajo izquierda) y foto de la cobertura del suelo en la parcela (abajo derecha).



*Figura 4. Puntos de muestreo puros, estables y confiables.*

### 2.3.1.2 Datos de sensores remotos

En virtud de que los humedales se desarrollan bajo regímenes hidrológicos particulares, es necesario comprender las características del entorno hidrológico, interanual e intraanual, en todas las regiones del país. Como se mencionó en el apartado 2.3, los ciclos de fases húmedas y secas se manifiestan en una expansión o contracción del humedal. Esta característica hace necesario abordar un enfoque multitemporal, lo suficientemente amplio para incluir períodos de oferta hídrica contrastantes. Para ello seleccionamos 54720 imágenes satelitales de los sensores Landsat 5 TM Colección 1 TOA (top-of-atmosphere, por sus siglas en inglés) y Landsat 8 colección 1 TOA, adquiridas entre el 1 de octubre y 31 de enero o 1 de abril y 30 de setiembre (según regiones) en un período de 20 años (2000-2020), a las que aplicamos un filtro para trabajar con imágenes libres de nubes (bandas BQA672 y BQA2720) (ver detalles del código desarrollado en JavaScript de GEE en el Anexo III). Posteriormente, obtuvimos, de cada imagen, los índices de vegetación de diferencia normalizada (NDVI), de vegetación ajustado al suelo (SAVI), de humedad de diferencia normalizada (NDWI) (Gao, 1996) y normalizado de humedad modificado (MNDWI) (Xu, 2006), según las siguientes ecuaciones:



$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}} \quad (1)$$

$$\text{SAVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red} + L} \times (1 - L) \quad (2)$$

$$\text{NDWI} = \frac{\text{NIR} - \text{SWIR}_{(1\ y\ 2)}}{\text{NIR} + \text{SWIR}_{(1\ y\ 2)}} \quad (3)$$

$$\text{MNDWI} = \frac{\text{Green} - \text{SWIR}_{(1\ y\ 2)}}{\text{Green} + \text{SWIR}_{(1\ y\ 2)}} \quad (4)$$

Donde Green, Red, NIR y SWIR 1 y 2 corresponden a las bandas 2, 3, 4, 5 y 7 en imágenes Landsat 5 y a las bandas 3, 4, 5, 6 y 7 en imágenes Landsat 8. A partir de estas bandas y de los índices generados, calculamos la mediana, media y desvío estándar y generamos una composición (stack) con los estadísticos, los índices y las bandas multiespectrales (ver código en Anexo III).

### 2.3.1.3 Datos topográficos

Para una aproximación a las características hidrogeomorfológicas, utilizamos el Modelo Digital de Elevación de Argentina (MDE-Ar v2.0), proporcionado por el Instituto Geográfico Nacional (IGN), con una resolución espacial de 30 m. A partir de este modelo derivamos dos variables de entrada: el Índice de Humedad Topográfica (TWI) y el Índice de Posición Topográfica (TPI). Ambos índices se calcularon mediante el programa libre System for Automated Geoscientific Analyses (SAGA; Conrad et al. 2015).

El TWI es un indicador de la humedad del suelo en un píxel determinado, por lo que permite identificar los potenciales lugares donde se concentra la humedad o las zonas de acumulación de agua, atributo estrechamente relacionado con la ubicación y extensión de los humedales. El TPI representa la posición de elevación en el terreno de cada píxel, en relación con la elevación media de los píxeles vecinos, por lo que los valores negativos indican que un píxel es más bajo que sus alrededores (ej. un valle) y los valores positivos indican lo contrario (ej. una loma). Este índice permite identificar zonas bajas o depresiones locales, muchas veces indicadores de zonas húmedas.

### 2.3.2 Selección del modelo y determinación espacial de humedales

A partir de la amplia disponibilidad de imágenes satelitales son varios los métodos y técnicas que permiten delinear y clasificar los humedales con gran precisión. GEE ofrece en su plataforma, un conjunto de algoritmos de clasificación, de gran aplicación en cartografía de coberturas terrestres (Hird et al. 2017; Farda et al. 2017; Berhane et al. 2018; McCarthy et al. 2018; Amani et al. 2019a; 2019b; Lamb et al. 2019; Mahdianpari et al. 2019). Seleccionamos el modelo de clasificación que mejor ajustó a los diferentes ambientes de Argentina, comparando cuatro algoritmos: Random Forest (RF), Máquina de Vectores de Soporte (SVM), Árboles de Clasificación y Regresión (CART) y Máxima Entropía (MaxEnt), utilizando un conjunto de datos de referencia. En base al mejor desempeño, seleccionamos RF para determinar la probabilidad de ocurrencia de humedales. RF es un algoritmo de aprendizaje automatizado que combina el muestreo de remuestreo (bootstrap) para construir árboles de decisión individuales, a partir de los cuales se determina la asignación de clase final (Breiman 2001). RF es muy eficaz para cartografiar con precisión la cobertura del suelo en paisajes altamente complejos y heterogéneos (Rodríguez-Galiano et al. 2012) como el de la República Argentina y más aún sus humedales. Además, RF funciona eficazmente con grandes volúmenes de datos, haciéndolo adecuado para cartografías a escalas que comprenden millones de hectáreas (Rodríguez-Galiano et al. 2012). La selección de los parámetros óptimos para el modelo RF, consistió en modificar iterativamente la complejidad del árbol (número de árboles), el número de variables por nodo y el número de semillas que permitiera mantener replicabilidad del modelo. De este análisis, seleccionamos 100 árboles de decisión, con 5 variables por nodo, un tamaño de nodo terminal de 5 y un valor de 5 para el número de semillas. Posteriormente, analizamos el rango de importancia de las variables mediante el módulo “explain”, , seleccionando en cada región las variables que demostraron mejor desempeño (Figura 5). Finalmente, recodificamos todas las clases de coberturas a la forma binaria 1-0, asignando 1 a todas las clases de humedales y 0 a no humedales.

Posteriormente, transformamos los valores de frecuencia, obtenidos a partir de la clasificación, a valores a probabilidad. Para esto, realizamos un análisis de regresión logística binaria a partir del conjunto de datos de referencia relevados a campo, usando el complemento Xrealsatistics, de Excel. En este caso, la variable independiente fue la presencia/ausencia del humedal y la variable explicativa, la frecuencia. Con base en los coeficientes obtenidos (Anexo V), desarrollamos una rutina de transformación en GEE (Figura 6) a partir de la cual obtuvimos finalmente los valores de probabilidad para cada píxel del mapa de humedales.

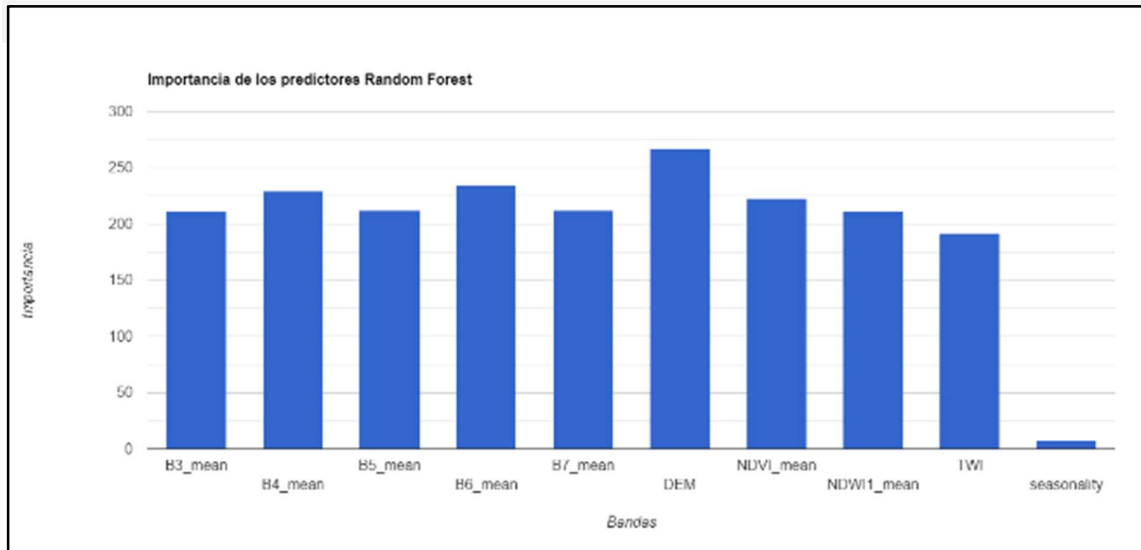


Figura 5. Ejemplo de análisis de importancia relativa de las variables predictoras del modelo RF; en este caso última corrida del modelo donde se descarta el predictor “seasonality”.

```
// Código para obtener el valor de probabilidad como tipo float
var probabilidad = imageCollection.map(function(img){
  return img.expression('e**((Coef1 + Coef2*Fre)/(1 + e**((Coef1 + Coef2*Fre)))', {
    e : 2.718281828,
    Coef1 : -3.43569119844288,
    Coef2 : 8.34799745953052,
    Fre : img.select('b1')})
  .rename('Probabilidad');
});
```

Figura 6. Código (script) para transformar los valores de frecuencia a valores de probabilidad

### 2.3.3 Evaluación de la exactitud de la determinación de los humedales

La validación consistió en la toma de datos a campo y en el uso de datos proporcionados por otros trabajos (Oliva et al. 2020; Gaitán et al. 2021). La Figura 7 muestra que la mayoría de los datos tomados a campo, especialmente de humedales, se recogieron en la región de clima húmedo (centro-este del país) y en la región templada-fría (este de Patagonia), las que corresponden a regiones de mayor proporción de humedales y mejor accesibilidad. Tomamos puntos individuales, tanto en humedales como en no humedales, mientras que, para validar el gradiente o elasticidad del humedal, trazamos transectas desde el ambiente de seco hasta el límite de la presencia de agua y/o claro reconocimiento del humedal. En cada punto evaluamos la presencia de las características diagnósticas de un humedal: i) presencia de agua superficial o subsuperficial; ii) presencia de vegetación adaptada (plantas hidrófitas); iii) suelos hídricos o sustratos con rasgos de hidromorfismo (Foto 1). El Anexo IV muestra la planilla de

campo utilizada para el relevamiento de la información. Para el reconocimiento de suelos




Figura 7. Ubicación de los puntos de muestreo obtenidos a campo.

hídricos excavamos cajas de observación con una profundidad de hasta 50 cm (USDA 2018) y evaluamos la presencia de características morfológicas distintivas de suelos hídricos. A fin de evitar una sobreestimación o sesgo en la precisión, de cualquiera de las dos clases, realizamos un muestreo balanceado. En total obtuvimos 4850 puntos de muestreo (51% correspondientes a humedales y 49% a no-humedales) lo que representa aproximadamente el 30% de los datos utilizados para la clasificación.

Superpusimos el conjunto de datos de campo a nuestro mapa y creamos un búfer de un píxel (1m) para cada punto, lo que permitió evitar pequeñas imprecisiones de posición. A partir de estos datos construimos una matriz de

confusión, obteniendo el coeficiente Kappa, la exactitud global, la exactitud del productor y del usuario. Para la evaluación de exactitud en las Islas Malvinas, dado la imposibilidad de acceder a la región, utilizamos como base el mapa elaborado por el proyecto Costal Habitat Mapping (Golding and Black 2020).

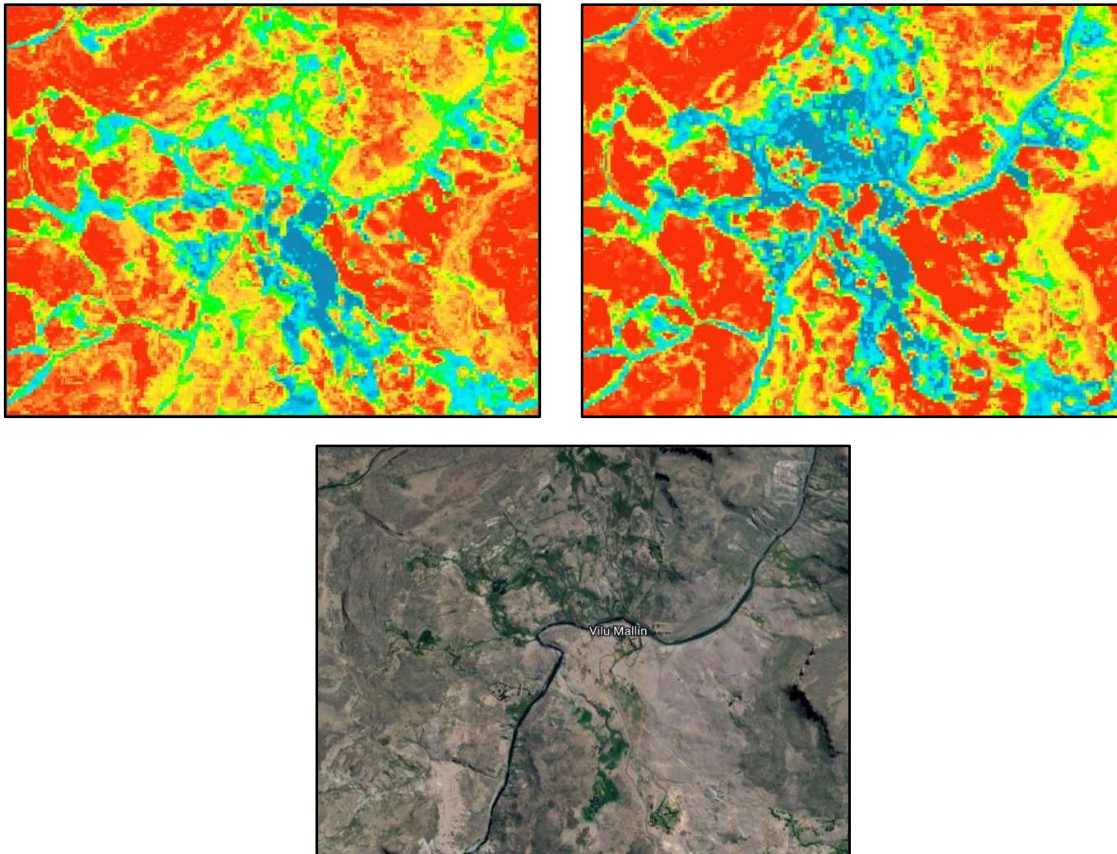




Foto 1. De izquierda a derecha, fila superior: presencia agua superficial (Subregión 8b), presencia agua subsuperficial (Subregión 8a), vegetación hidrófila (*Typha latifolia* o totora, Región 2); fila inferior: vegetación hidrófila (*Thalia geniculata* y otras), rasgos hidromórficos en suelo hídrico (Subregión 8b); rasgos hidromórficos en sustrato (salina, Región 7)

### 3. RESULTADOS y DISCUSIÓN

Si bien los humedales comparten características similares, tales como la presencia de agua, vegetación hidrófila y/o suelos hídricos, la forma en que se combinan estos sumado a las características particulares del sitio de emplazamiento de cada humedal, genera no solo los distintos tipos de humedales sino también diferencias entre los mismos tipos, por lo que distinguirlos utilizando conjuntos de datos de teledetección y algoritmos de aprendizaje automatizado ha sido un desafío. Por otro lado, esta complejidad en la determinación reside también en su gran dinamismo, los humedales pueden cambiar significativamente en cortos períodos de tiempo. Esto hace que sus características espectrales difieran según meses, estaciones y años. Por ejemplo, según se observa en la Figura 8, el mallín (ubicado en el área central de la escena) presenta un aspecto diferente en verano en relación al invierno, época donde hay una mayor presencia de agua y, por lo tanto, sus características espectrales son diferentes en las imágenes satelitales de cada estación. Esto refleja la importancia de realizar



*Figura 8. Ejemplo de clasificación de mallines (Vilu Mallín, Neuquén) en diferentes estaciones. Arriba, a la izquierda corresponde al período de octubre a marzo, mientras que, a la derecha, corresponde al período de abril a setiembre.*

una clasificación o mapeo mediante un enfoque multitemporal, a fin de mejorar la precisión en la determinación de los humedales.

La Figura 9 muestra el conjunto de datos de humedales relevados a campo en función de sus valores de frecuencia obtenidos a partir de la clasificación, evidenciando un pronunciado incremento positivo entre la frecuencia de 0,5 y 0,6; luego la pendiente se hace más suave entre los valores de 0,6 y 0,7, a partir de allí muestra otro fuerte incremento hasta un valor de frecuencia cercano a 1. Es necesario aclarar que la frecuencia refiere a la cantidad de veces que el clasificador le otorgó la categoría correcta a la clase. Esto nos permite definir cuatro rangos de frecuencia: 0 – 0,5; 0,5 – 0,6; 0,6 – 0,7 y; 0,7 – 1,0. El primer rango, con valores inferiores a 0,5, corresponde a coberturas del suelo diferentes a humedales y cuerpos de agua profunda, mientras que a partir del valor de 0,5 comienzan a distinguirse los humedales.

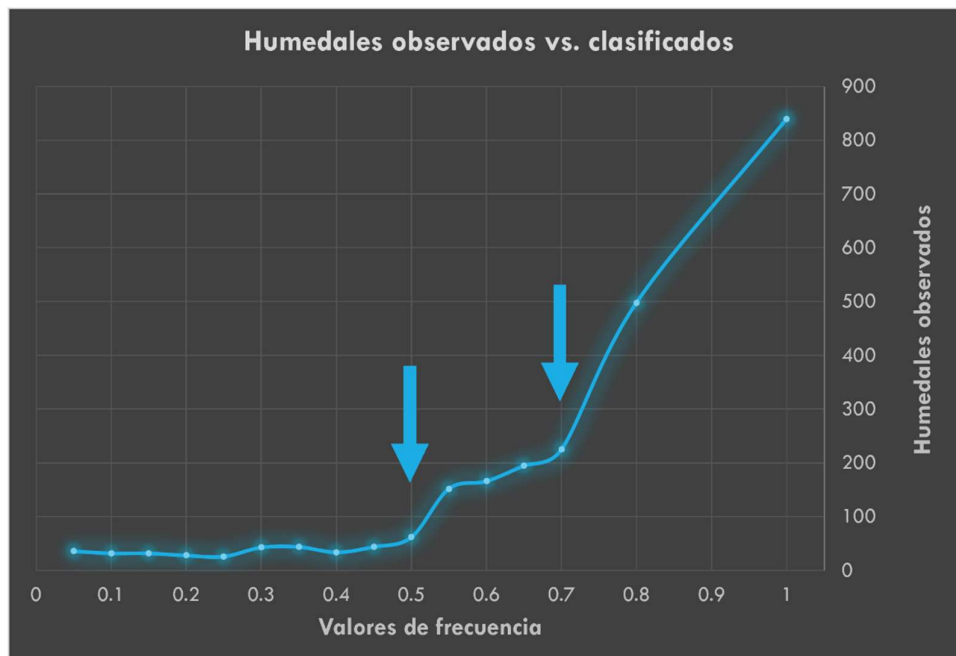


Figura 9. Superposición del conjunto de datos obtenidos a campo al mapa de frecuencia de humedales.

La Figura 10 muestra el mapa de frecuencia de humedales, obtenido mediante la aplicación del algoritmo de aprendizaje automatizado Random Forest, imágenes multitemporales de Landsat 5 y 8 (20 años), dentro de la plataforma GEE, agrupando las distintas coberturas terrestres en dos clases: humedales y no humedales. A fin de una mejor visualización subdividimos el cuarto rango de valores, en dos: 0,7 – 0,8 y 0,8 – 1,0. Observamos que la mayor concentración de humedales se encuentra en la región centro este y noreste del país, lo cual coincide con trabajos previos (Kandus et al. 2008; Godagnone et al. 2016). Luego, continúa la región este y extremo sur de la Patagonia, donde se concentra la mayor cantidad de mallines y turberas del país, respectivamente, mientras que en el extremo noroeste se evidencia la presencia de escasos humedales, pero de gran superficie, lo que se corresponde con la principal región de salinas del país.



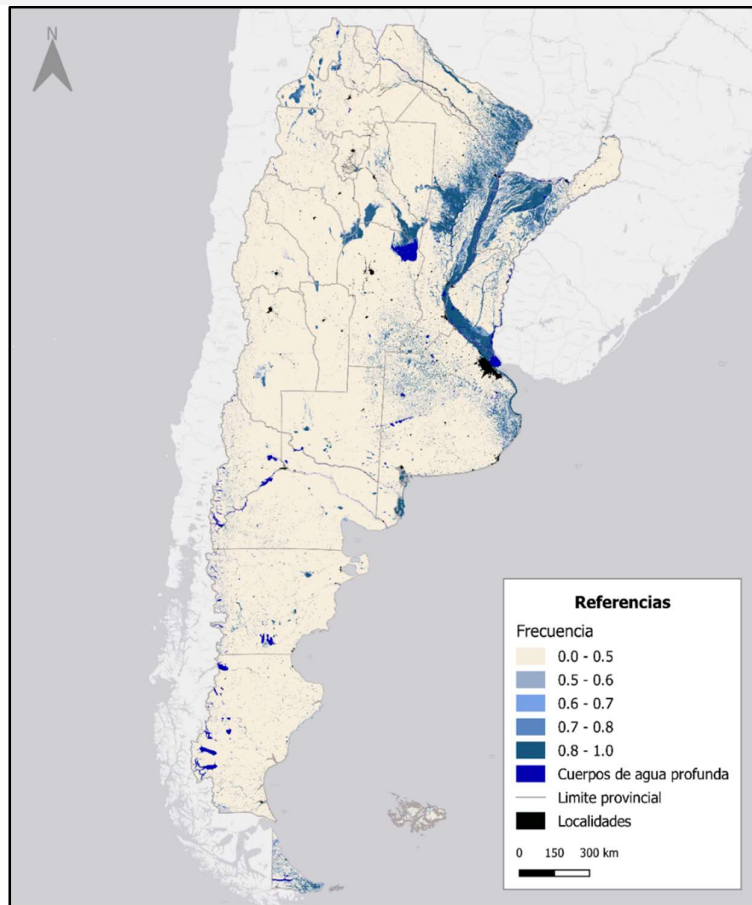


Figura 10. Mapa de frecuencia de humedales en la República

En dos áreas ampliadas de distintas regiones del país podemos apreciar el gradiente entre la zona más externa del humedal o de contacto con las otras coberturas de la tierra, y el área central del mismo (Figura 11). Este gradiente, que presenta mayormente valores de frecuencia entre 0,5 y 0,7 se corresponden, en general, con la zona de elasticidad del humedal, cuya expresión es claramente visible en la imagen superior derecha. Este gradiente de valores coincide con observaciones directas realizadas a campo mediante transectas realizadas a fin de poder determinar los valores dentro dicho gradiente. Sin embargo, también observamos, no solo a campo sino también en imágenes de alta resolución, que, en varios casos, algunos valores de frecuencia dentro este rango (0,5 – 0,7) se correspondía con una disminución paulatina de la superficie del humedal. Esto puede ser atribuido tanto a una mayor presión de uso en áreas circundantes, al avance de la frontera productiva (drenaje) como al posible efecto de la disminución de precipitaciones y aumento de la temperatura en los últimos años (cambio climático). Es necesario notar que, muchos de los humedales en las regiones andinas y/o serranas, particularmente ríos y arroyos, también presentaron valores de frecuencia dentro de este rango, principalmente por la acotada presencia del agua que es de régimen estacional.






Figura 11. Imagen superior: clasificación de dos lagunas en la Provincia de Buenos Aires (Región 8b). Imagen inferior: clasificación de mallines en la Provincia de Neuquén (Región 10a)

A partir del mapa de frecuencia y mediante un modelo de regresión logística, se transformaron los valores de frecuencia a probabilidad. La relación entre la frecuencia y la probabilidad de ocurrencia de humedales muestra que el valor de probabilidad a partir del cual se puede considerar la presencia de un humedal es alrededor de 0,7 o 70% (Figura 12).




Figura 12. Ajuste entre valores de frecuencia y probabilidad de ocurrencia de humedales

La Figura 13 muestra el mapa de probabilidad de ocurrencia de humedales resultante tras la aplicación de la regresión logística.

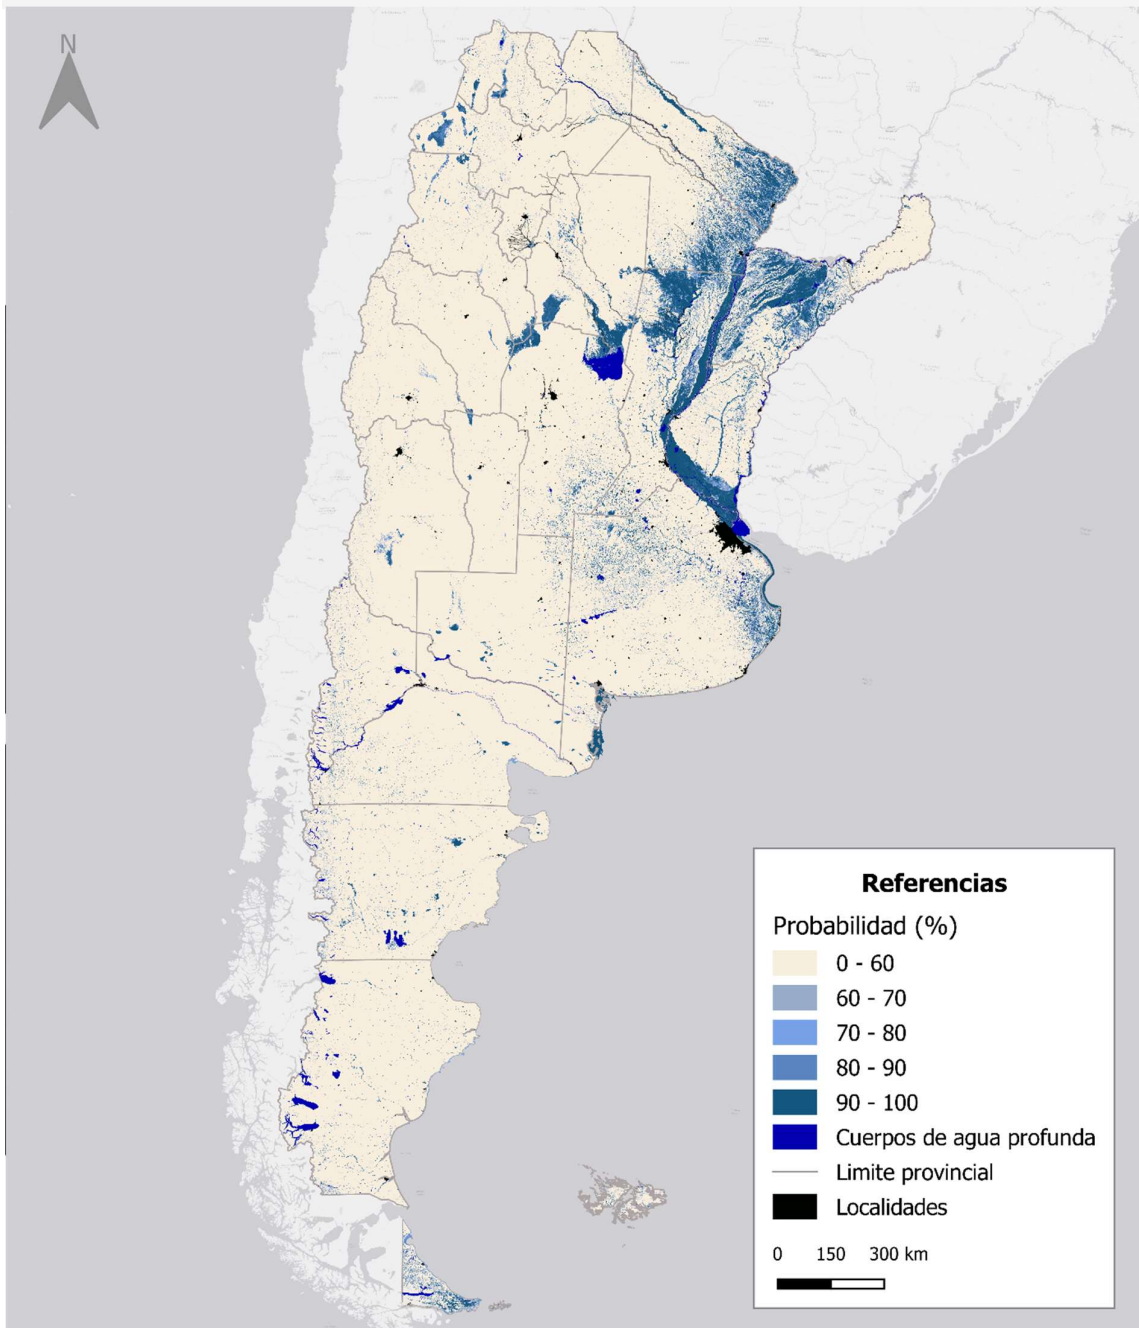


Figura 13. Mapa de probabilidad de presencia de humedales de Argentina.

Patrones de probabilidad de ocurrencia de humedales y características del paisaje, tales como ríos, lagunas y llanuras aluviales, fueron determinados con un muy buen ajuste (representación fidedigna). Esto lo podemos observar en dos áreas ampliadas mediante la comparación del mapa de probabilidad de ocurrencia de humedales junto con imágenes de



alta resolución (Figura 14). Asimismo, observamos que los pequeños cuerpos de agua fueron captados y delineados con razonable exactitud.

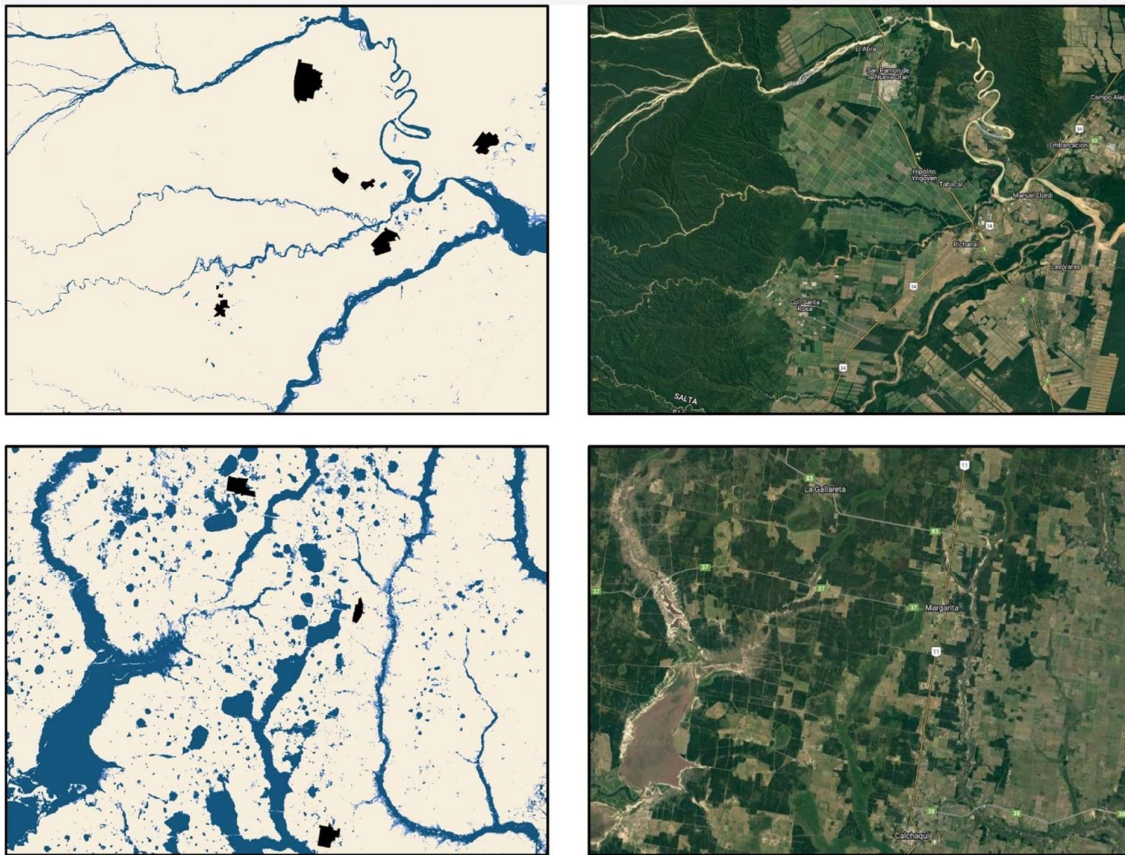


Figura 14. Imagen superior: clasificación de una sección del río Bermejo, su llanura aluvial y tributarios (Salta, Región 1). Imagen inferior: clasificación de la laguna Cristal, otras pequeñas lagunas y tributarios del río Paraná (Santa Fe, Región 2 y 5a).

La Tabla 2 muestra el área ocupada por humedales según las regiones, evidenciando que las regiones del NEA son las que presentan mayor superficie (km<sup>2</sup>). La superficie total de humedales de Argentina, considerando como tales a todos aquellos píxeles con valor de probabilidad superior a 70% asciende a aproximadamente 265.200 km<sup>2</sup>, lo que representa el 9,5% de la superficie total del país. De estos, aproximadamente el 1% (30.500 km<sup>2</sup>) corresponde al rango 70-80%, mayormente zona de elasticidad del humedal, el 1,5% (42.800 km<sup>2</sup>) al rango 80-90%, zona de elasticidad y ríos y arroyos serranos y de montaña, mientras que el 7% restante (192.000 km<sup>2</sup>) corresponde al rango 90-100% (Tabla 2 y Figura 15). La superficie total estimada por nosotros coincide con estimaciones realizadas a nivel mundial, según el Global Wetlands (Gumbricht et al. 2017, <https://www2.cifor.org/global-wetlands/>), el 9,3% (259.200 km<sup>2</sup>) de Argentina estaría cubierta por humedales. Esta estimación es similar a la obtenida en este trabajo, sin embargo, en la estimación final incluyeron los cuerpos de agua profunda, los cuales en conjunto tienen una superficie de aproximadamente 8.700 km<sup>2</sup>, pero no consideraron las salinas ni los humedales costeros. Por otro lado, es importante

destacar que, si bien el porcentaje total de humedales es similar, presenta claras diferencias en la distribución espacial de los mismos, especialmente en la región norte del país.

Tabla 2. Superficie (km<sup>2</sup>) ocupada por humedales según las regiones de humedales del país.

REGION	Código región	PROBABILIDAD			Total
		70-80	80-90	>90	
			Superficie en km <sup>2</sup>		
Región Humedales Montanos Precordilleranos y Subandinos	1	81	114	541	<b>816</b>
Región Humedales del Chaco	2	3567	4286	29005	36858
Subregión Vegas Lagunas y Salares de la Puna	3a	1492	2760	6239	11914
Subregión Vegas y Lagunas Altoandinas	3b	640	580	443	2455
Región Humedales Misioneros	4	159	195	501	855
Subregión Ríos Esteros Bañados y Lagunas del Río Paraná	5a	2462	4247	57237	63946
Subregión Riachos Esteros y Bañados del Chaco Húmedo	5b	3931	6065	28256	38252
Subregión Malezales Tembladerales y Arroyos Litoraleños	5c	3013	4012	12232	19257
Subregión Ríos y Arroyos de los Valles Intermontanos	6a	589	410	230	2033
Subregión Arroyos y Mallines de las Sierras Centrales	6b	61	49	167	375
Subregión Salinas de la Depresión Central	6c	351	1044	8224	9956
Región Humedales del Monte Central	7	1504	1446	2547	5497
Subregión Lagunas de la Pampa Húmeda	8a	3212	4223	14086	21521
Subregión Lagunas Salobres de la Pampa Interior	8b	2200	3947	10453	16600
Subregión Playas y Marismas de la Costa Bonaerense*	9a	657	1193	5817	7667
Subregión Playas y Marismas de la Costa Patagónica *	9b	734	1039	3756	5529
Subregión Lagos Cursos de Agua y Mallines Patagónicos	10a	2208	2100	1922	8649
Subregión Lagunas y Vegas de la Patagonia Extrandina	10b	1866	2168	7133	13248
Subregión Mallines y Turberas de la Patagonia Sur	10c	2049	2923	2950	7922
		<b>30504</b>	<b>42804</b>	<b>191888</b>	<b>265196</b>
					<b>9.54%</b>

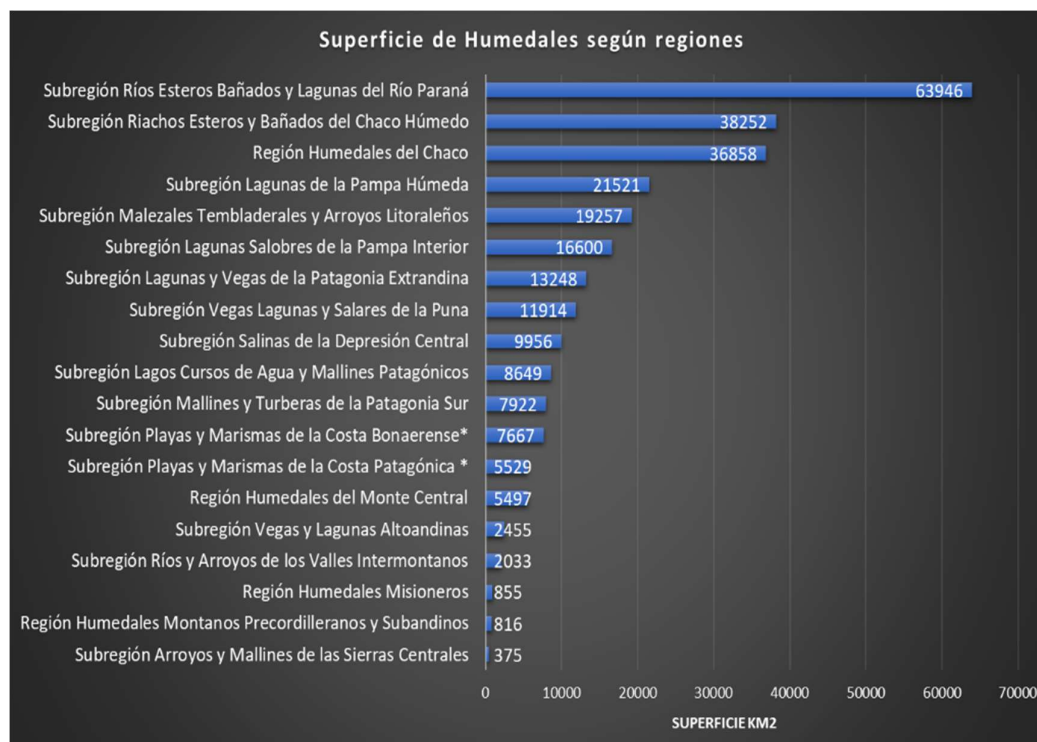


Figura 15. Superficie ocupada por humedales según regiones, ordenada en forma decreciente.



La exactitud global y el coeficiente kappa de nuestro mapa fue del 89.3% y 0.72, respectivamente. Además, la exactitud del productor y del usuario (especificidad y precisión, respectivamente) para la clase humedales fue, en ambos casos, del 94%, mientras que la exactitud del productor de la clase no humedales (sensibilidad) fue del 85%. Este nivel de precisión es un muy buen resultado teniendo en cuenta la inmensidad del área clasificada y en comparación con resultados de trabajos llevados a cabo en otras partes del mundo y con metodologías similares, en los cuales la precisión varió entre 71 – 95% (Tabla 3)

*Tabla 3. Valores de exactitud global obtenidos en diferentes trabajos de clasificación de humedales*

<b>Exactitud global (%)</b>	<b>Algoritmo clasificación</b>	<b>Fuente</b>
75 – 90	RF	Farda, 2017
91 – 94	RF	Chatziantoniou et al., 2017
71	RF	Amani et al, 2019a
85 - 93	RF	Chimmer et al., 2019
78 - 85	BRT	Hird et al, 2017
78 - 84	RF	Amani et al., 2019b

Si bien en este trabajo hemos alcanzado un alto valor de precisión, hay ciertos factores que influyeron introduciendo cierto grado de confusión, los cuales son discutidos a continuación.

Entre las mayores confusiones que influyeron en la exactitud del mapa de humedales producido, se presentaron, principalmente, en zonas de riego en las regiones áridas y semiáridas del país. En varios casos, tanto los oasis de riego en la región de cuyo como los valles y llanuras aluviales, cultivados principalmente por especies frutales en la región norandina y en el norte de Patagonia, presentaron sobreestimaciones con valores de frecuencia entre 0,5 y 0,6 (probabilidad 70 y 80%, respectivamente). Por ejemplo, la Figura 16 ilustra la distribución de valores de frecuencia en una sección del Alto Valle del Río Negro, donde se observa parcelas cultivadas con grupos de píxeles cuyos valores de frecuencia oscilan entre los valores mencionados. Esta sobreestimación podría deberse, por un lado, a que el período de selección de imágenes para esas regiones (primavera-verano) coinciden con la época de riego y de máximo crecimiento de la vegetación, lo que genera un alto contraste con la vegetación circundante (mayormente estepa mixta o estepa arbustiva) y, por otro lado, a la presencia de agua en los canales de riego que. Para corroborar esto, y teniendo en cuenta que en la mayoría de los casos el cambio de cobertura era anterior al año 2000, realizamos relevamientos a campo, evaluando la existencia o no de suelos hídricos o bien de acentuados rasgos hidromórficos en los primeros 30 - 50 cm del suelo que permitiera inferir la existencia previa del humedal. De los 42 sitios muestreados en el Valle del Río Negro, entre las

localidades de Gral. Roca y Choele-Choel, solo 10 presentaron suelos hídricos y se correspondían con áreas no cultivadas.





Figura 16. Escena ampliada del Alto Valle del Río Negro, mostrando áreas de confusión en parcelas cultivadas con especies frutales (Río Negro, Región 10b)

Por otro lado, en muchos casos, las rutas y caminos también mostraron valores de frecuencia entre 0,5 y 0,7 (probabilidad 70 a 90%), como consecuencia, principalmente, de la presencia de zanjas o canales de drenaje, normalmente con agua y vegetación hidrófila, que discurren a lo largo del camino en uno o ambos lados (Figura 17). En futuros trabajos, este efecto podría ser resuelto mediante el uso de máscaras de las redes viales con un búfer de ancho ajustado al tipo de red vial.



*Figura 17. Escena ampliada de un tramo de la Ruta Prov. 5 en la provincia de Corrientes (Subregión 5a)*

En cuanto a los datos de origen de las variables clave utilizadas en nuestro modelo, los datos digitales de elevación (MDE) presentan errores en áreas con doseles altos (elevan artificialmente la altura del suelo), afectando particularmente al TWI. Esto se observó principalmente en las regiones de llanuras del país donde hay pequeños grupos o parches de árboles, muchas veces para sombra del ganado o bien en el uso de cortinas arbóreas. La tendencia general de estos errores es una sobreestimación de la profundidad de la pendiente. Al comparar nuestras estimaciones con imágenes de alta resolución, encontramos un sesgo que afectaba principalmente a los píxeles cercanos, los cuales mostraban valores de frecuencia entre a 0.5 y 0.6. Para evitar este sesgo, decidimos no utilizar el TWI en las regiones donde este error se hiciera relevante.

Finalmente, es importante notar que, si bien el análisis multitemporal de largos períodos de tiempo presenta ventajas al captar la dinámica propia de los humedales al incluir en el análisis períodos de abundancia hídrica y otros de escasez, presenta también desventajas a la hora de reconocer coberturas estables por largo tiempo. Esto se hizo más evidente en regiones donde los cambios de cobertura y/o uso son más frecuentes, como, por ejemplo, cuerpos de agua que han sido o han comenzado a drenarse en algún momento del período analizado y, por lo tanto, los valores de probabilidad resultan más bajos que el de otros cuerpos de agua similares en áreas cercanas. Similar situación presenta nuevas zonas de acumulación de agua que, generadas a partir de la construcción de rutas o caminos, pueden permanecer con agua por largos períodos de tiempo. Para futuros estudios, y teniendo ya como antecedente este trabajo,

#### **4. CONSIDERACIONES FINALES**

La superficie total de humedales en cada región se calculó acorde al tamaño de píxel de estos en cada lugar del territorio nacional. Así, por ej., para la Región 10c, la zona que corresponde a Santa Cruz el valor del píxel en WGS84 es de 0.00026949459 lo que equivale a

24.25 m, por lo que el píxel pasa a ser de 588 m<sup>2</sup>, o sea, 0.0588 ha, mientras que, para Tierra del Fuego, el píxel es de 23.96 m, por lo tanto, equivale a 0.0574 ha.

Dado que en este trabajo hemos propuesto un abordaje a nivel de país, humedales de escasa dimensión areal o de angosta envergadura no han podido ser determinados correctamente en el proceso de clasificación, ya sea en toda su extensión o en partes, tal es el caso de muchos ríos o arroyos inferiores a 60 m de ancho o pequeños cuerpos de agua (lagos, lagunas, estanques) menores a 4 ha. Esto se debe particularmente a la resolución espacial de las imágenes satelitales utilizadas y la confusión que se genera con las clases de cobertura adyacente al humedal. Teniendo en cuenta esto y, a pesar de que el presente trabajo es el producto de una clasificación supervisada de imágenes satelitales por lo que no posee escala cartográfica ni área mínima mapeable, para facilitar una gestión del territorio y, considerando lo propuesto por diversos autores (Priego et al. 2008, Salitchev, 1979; Priego et al., 2008; Lencinas and Siebert, 2009; Marquina and Mogollón, 2018), se recomienda asumir una escala mínima de 1:50.000 y un área mínima mapeable o reconocible de 4 ha.

Un problema común en la determinación y mapeo de humedales es que muchos de ellos están localizados en lugares distantes o de difícil acceso, por lo que la recopilación de datos de campo es difícil y costosa. Si bien en este caso se recopiló una cantidad relativamente alta y de calidad (30% del total de datos de referencia), es necesario aumentar la cantidad de muestras de campo, particularmente en las regiones andinas, para aumentar la precisión de la clasificación en futuras actualizaciones.

Cabe resaltar que la validación a campo se llevó adelante en un periodo de sequía no registrada desde 1880. En este contexto, la mayoría de los humedales en todo el territorio nacional se encuentran drásticamente afectados, viéndose reducidos en su extensión. Esto generó un gran desafío para su reconocimiento, atendiendo a que el principal rasgo distintivo es la presencia de agua.

Por último, a pesar de que en este tipo de mapas es común aplicar filtros que eliminen el ruido introducido por pequeños grupos de píxeles o bien píxeles aislados y, no obstante lo aclarado anteriormente en cuanto a la recomendación sobre la escala de trabajo, en esta oportunidad consideramos no aplicar ningún filtro debido a que, dada la sequía que se registra en gran parte del país en los últimos años, estos píxeles pueden representar humedales fuertemente afectados, pero que en épocas de mayor oferta hídrica puedan volver a su condición normal.



## 5. CONCLUSIONES

En los últimos años, el interés por la conservación y uso racional y sostenible de los humedales ha ido en incremento, por lo tanto, la necesidad de identificar su ubicación y extensión en todo el país y contar con una herramienta que permita monitorear sus cambios a lo largo del tiempo es de gran relevancia. Si bien existen algunas estimaciones previas, las mismas se basaron casi exclusivamente en una de las tres características distintivas de los humedales y a partir de información a escalas exploratorias, lo que puede llevar a sobrestimar la extensión real de los mismos. Por consiguiente, en este trabajo propusimos e implementamos un método dentro de la plataforma Google Earth Engine (GEE), para generar un mapa que identifique y estime la superficie de humedales en el país, que pueda ser replicado en cualquier parte del territorio nacional, a partir de información que permite inferir sobre estas características. El mapa resultante se validó a campo y se evaluó estadísticamente. En cuanto a la verificación a campo, muchas características del mapa presentado se correspondían con lo observado directamente en el terreno y fue oportunamente discutido. Aquí es central remarcar la importancia de este relevamiento para obtener información precisa y fehaciente que permitió una mejor validación de la clasificación. En cuanto a la evaluación estadística, se registró una precisión global del 89.3% al distinguir humedales de no humedales. Este resultado demuestra un alto nivel de precisión, más cuando se considera la superficie de Argentina (2,78 Millones km<sup>2</sup>), el bajo costo del estudio y la eficiencia del método propuesto. Es importante destacar que acorde a nuestras estimaciones, aproximadamente el 9.5% de Argentina está cubierto por humedales. Este resultado es considerablemente menor al de las estimaciones previas mencionadas, y se ajusta a la estimación más actual propuesta por el Global Wetlands, si bien difiere en su distribución en algunas regiones del país, lo que se atribuye a la diferencia de escala e información de base utilizada. En este trabajo demostramos que la probabilidad de presencia de humedales en Argentina puede ser modelada de manera precisa y con buen éxito, involucrando una serie multitemporal de 20 años de imágenes satelitales de resolución media, datos topográficos y el modelo de aprendizaje automatizado RF, en una plataforma de acceso libre como GEE. Sin embargo, entendemos que aún hay mejoras que se pueden hacer como la inclusión de una clasificación con un enfoque subpíxel, y un mayor conjunto de datos de campo para aumentar la precisión. No obstante, consideramos que este trabajo constituye una excelente base para el estudio de la dinámica, pasada y futura, de los humedales, para el desarrollo de inventarios de estos ecosistemas y un sólido aporte a los Objetivos de Desarrollo Sostenible, particularmente el indicador 6.6.1 *“Cambio en la extensión de los ecosistemas relacionados con el agua a largo plazo”*. Consideramos que es también una herramienta sólida para la gestión del territorio y la toma de decisión. Finalmente, queremos extender una invitación a otras instituciones a sumar esfuerzos e incrementar la base de datos de campo a fin de mejorar la exactitud de este y futuros trabajos en cuanto a la distribución y dinámica de los humedales.

## 6. AGRADECIMIENTOS

Queremos agradecer particularmente a la red MARAS (Monitoreo Ambiental en Regiones Áridas y Semiáridas) y al Proyecto INTA-TNC “Pasturas Chaqueñas” por el invaluable aporte de datos de campo para la validación del presente trabajo.

## 7. REFERENCIAS

- Amani, M., Brisco, B., Afshar, M., Mohammad Mirmazloumi, S., Mahdavi, S., Mohammad Javad Mirzadeh, S., Huang, W., Granger, J. **2019a**. A generalized supervised classification scheme to produce provincial wetland inventory maps: an application of Google Earth Engine for big geo data processing, *Big Earth Data*, 3:4, 378-394, <https://doi.org/10.1080/20964471.2019.1690404>
- Amani, M., Mahdavi, S., Afshar, M., Brisco, B., Huang, W., Mohammad Javad Mirzadeh, S., Hopkinson, C. **2019b**. Canadian wetland inventory using Google Earth Engine: The first map and preliminary results. *Remote Sens.*, 11(7), 842. <https://doi.org/10.3390/rs11070842>
- Berhane, T.M., Lane, C.R., Wu, Q., Bradley, c.A., Anenkhonov, O.A., Chepinoga, V.V., Liu, H. **2018**. Decision-tree, rule-based, and random forest classification of high-resolution multispectral imagery for wetland mapping and inventory. *Remote Sens.*, 10, 580. <https://doi.org/10.3390/rs10040580>
- Bey, A., Sánchez-Paus Díaz, A., Maniatis, D., Marchi, G., Mollicone, D., Ricci, S., Bastin, J.-F., Moore, R., Federici, S., Rezende, M. **2016**. Collect earth: land use and land cover assessment through augmented visual interpretation. *Rem. Sens.* 8, 807. <https://doi.org/10.3390/rs8100807>
- Benzaquen, L., Blanco, D., Bo, R., Kandus, P., Lingua, G., Minotti, P., Quintana, R. **2017**. Regiones de humedales de la Argentina, 337 pp
- Breiman, L. **2001**. Random Forest. *Mach. Learn.*, 45,5-32
- Chatziantoniou, A., Petropoulos, G.P., Psomiadis, E. **2017**. Co-orbital Sentinel 1 and 2 for LULC Mapping with emphasis on wetlands in a Mediterranean setting based on machine learning. *Remote Sens.*, 9, 1259. <https://doi.org/10.3390/rs9121259>
- Chimmer, R.A., Bourgeau-Chavez, L., Grelik, S., Hribljan, J.A., Planas Clarke, A.M., Polk, M.H., Lilleskov, E.A., Fuetelba, B. **2019**. Mapping mountain peatlands and wet meadows using multi-date, multi-sensor remote sensing in the Cordillera Blanca, Perú. *Wetlands*, 39, 1057-1067. Doi: <https://doi.org/10.1007/s13157-019-01134-1>
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., Böhner, J. **2015**. System for Automated Geoscientific Analysis (SAGA), v.2.1.4. *Geoscientific Model Development*, 8, 1991-2007
- Cowardin, L.M., Carte V., Golet, F.C., LaRoe, E.T. **1979**. Classification of wetlands and deepwater habitats on the United States. U.S. Department of the Interior, Fish and Wildlife Service, Washington, D.C., 131pp

- Fagan, M.E., DeFries, R.S., Sesnie, S.E., Arroyo-Mora, J.P., Soto, C., Singh, A., Townsend, P.A., Chazdon, R.L. **2015**. Mapping species composition of forests and tree plantations in Northeastern Costa Rica with an integration of hyperspectral and multitemporal landsat imagery. *Remote Sens.* 7: 5660-5696. <https://doi.org/10.3390/rs70505660>
- Farda, N.M. 2017. Multi-temporal land use mapping of coastal wetlands area using machine learning in Google Earth Engine. *IOP Conf. Series: Earth Environ. Science* 98, 012042
- Gaitán, J.J., Acuña, F., Agüero, W., Álvarez, C.A., Ballón, M., Banegas, N. et al. 2021. Cartografía del estado de degradación de las pasturas del Gran Chaco Americano. Informe Convenio de Asistencia Técnica INTA-The Nature Conservancy
- Gao, B. 1996. NDWI – a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.*, 58:3, 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gardner, R.C., Barchiesi, S., Beltrame, C. et al. **2015**. State of the World's wetlands and their services to people: a compilation of recent analyses. Gland, Switzerland
- Godagnone, R.E., De La Fuente, J.C., Taboada, M.A. **2016**. Humedales en Argentina. Informe para la Comisión de Ambiente y Desarrollo Sustentable del Honorable Senado de la Nación sobre la Ley de Presupuestos Mínimos para la Conservación, Protección y Uso Racional y Sostenible de los Humedales. Informe Técnico no publicado, 13 pp
- Golding, N., Black, B. **2020**. Coastal Habitat Mapping project. Final Report from the DPLUS065 Mapping Falklands and South Georgia coastal margins for spatial planning project. SAERI. <http://dataportal.saeri.org/dataset/a-broad-scale-satellite-derived-landcover-classification-habitat-map-for-the-falkland-islands-for-ja>
- Gopal, B., Kvet, J., Löffler, H., Masing, V., Pattern, B.C. **1990**. Definition and classification. En: Pattern, B.C. (ed) *Wetlands and shallow continental water bodies*. SPB Academic Publishing BV, The Hague, pp 9-15
- Gorelick, N., Hancher, M., Dixon, M., Ilyuschenko, S., Thau, D., Moore, R. **2017**. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.*, 202 (1), 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Gumbrecht, T., Román-Cuesta, R.M., Verchot, L.V., Herold, M., Wittmann, F., Householder, E., Herold, N., Murdiyarso, D. 2017. An expert system model for mapping tropical wetlands and peatlands reveals South America as the largest contributor. *Global Change Biology* 23(9):3581-3599. <https://doi.org/10.1111/gcb.13689>
- Hird, J.H., DeLancey, E.R., McDermid, G.J., Kariyeva, J. **2017**. Google Earth Engine, open-access data and machine learning in support of large-area probabilistic wetland mapping. *Remote Sens.*, 9, 1315. <https://doi.org/10.3390/rs9121315>
- Humphreys, J. et al. **2017**. Disaggregating the Patchwork: *Wet.* 37:205-219
- Jaramillo villa, U., Cortes-Duque, J., Florez-Ayala, C. **2015**. Colombia Anfibia. Un país de humedales I, Instituto Alexander Von Humboldt, Bogotá, 73 pp
- Junk, W.J., An, S., Finlayson, C.M., Gopal, B., Kvet, J., Mitchell, S.A., Mitsch, W.J., Robarts, R.D. **2013**. Current state of knowledge regarding the world's wetlands and their future

- under global climate change: a synthesis. *Aquat. Sci.* 75, 151–167. <https://doi.org/10.1007/s00027-012-0278-z>
- Kandus, P., Minotti, P. **2018**. Propuesta de un marco conceptual y lineamientos metodológicos para el Inventario Nacional de Humedales. Informe final. En: Documento Marco para el desarrollo del Inventario Nacional de Humedales de Argentina. Ministerio de Ambiente y Desarrollo Sostenible de Argentina, 56 pp.
- Keddy, P.A., **2010**. *Wetland Ecology: Principles and Conservation*. second ed. Cambridge University Press, Cambridge
- Khatami, R., Mountrakis, G., Stehman, S.V. 2016. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: general guidelines for practitioners and future research. *Remote Sens. Environ.* 177: 89-100. <https://doi.org/10.1016/j.rse.2016.02.028>
- Kingsford, R.T., Basset A., Jackson L., **2016**. Wetlands: conservation's poor cousins. *Aquat. Conserv. Mar. Freshw. Ecosyst.* 26: 892–916. <https://doi.org/10.1002/aqc.2709>
- Lamb, B.T., Tzortziou, M.A., McDonald, K.C. **2019**. Evaluation of approaches for mapping tidal wetlands of the Chesapeake and Delaware Bays. *Remote Sens.*, 11(20). 2366. <https://doi.org/10.3390/rs11202366>
- Lencinas, J.D., Siebert, A. **2009**. Relevamiento de bosques con información satelital: Resolución espacial y escala. *Quebracho*, 14, 1-2, 101-105
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, s., Gill, E. **2019**. The first wetland inventory map of Newfoundland at a spatial resolution of 10 m using Sentinel-1 and Sentinel-2 data on the Google Earth Engine cloud computing platform. *Remote Sens.*, 11 (1), 43. <https://doi.org/10.3390/rs11010043>
- Marquina, J.J. and Mogollón, A.R. **2018**. Niveles y escalas de levantamiento de información geográfica en sensores remotes. *Revista Geográfica Venezolana*, 59:1, pp 42+
- Marton, J.M., Creed, I.F., Lewis, D.B., Lane, C.R., Basu, N.B. et al. **2015**. Geographically isolated wetlands are important biogeochemical reactors on the landscape. *Bioscience*, 65(4), 408-418. <https://doi.org/10.1093/biosci/biv009>
- McCarthy, M.J., Radabaoug, K.R., Moyer, R.P., Muller-Karger, F.E. **2018**. Enabling efficient, large-scale high spatial resolution wetland mapping using satellites. *Remote. Sens. Environm.*, 208, 189-201. <https://doi.org/10.1016/j.rse.2018.02.021>
- Meixler, M., Bain M. **2010**. Landscape scale assessment of stream channel and riparian habitat restoration needs. *Land and Ecol.* 6(2):235-245. <https://doi.org/10.1007/s11355-010-0103-6>
- Millennium Ecosystem Assessment, **2005**. *Ecosystems and Human Well-Being: Wetlands and Water Synthesis*. Millennium Ecosystem Assessment Report to the Ramsar Convention. World Resources Institute, Washington, DC
- Mitsch, W.J., Gossilink J.G. **2007**. *Wetlands*. Wiley, Hoboken
- Neiff, J.J., Iriondo, M.H., Carignan, R. 1994. Large tropical south American wetlands: an overview. En: *Proceedings of the international workshop on the ecology and management of aquatic-terrestrial ecotones*, 156-165



- Plan Estratégico Español para la Conservación y el Uso Racional de los Humedales, en el marco de los ecosistemas acuáticos de que dependen.
- Oliva, G., Dos Santos, E., Sofía, O., Umaña, F., Massara, V., Martínez, G. G., Caruso, C., Cariac, G., Echevarría D., Fantozzi, A., Butti, L., Bran, D., Gaitán, J., Ferrante, D., Paredes, P., Domínguez, E., Maestre, FT. (2020). The MARAS dataset, vegetation and soil characteristics of dryland rangelands across Patagonia. *Scientific Data*, 7(1), 1-14. ONU. Departamento de Asuntos Económicos y Sociales. 2022. World Population Prospects. Summary of results, Nueva York, 52 pp
- Pekel, JF., Cottam, A., Gorelick, N., Belward, A. **2016**. High-resolution mapping of global surface water and its long-term changes. *Nature*, 540, 418-422 <https://doi.org/10.1038/nature20584>
- Priego-Santander, A., Bocco, G., Mendoza, M., Garrido, A. 2008. Propuesta para la generación semi automatizada de unidades de paisajes: Fundamentos y métodos. México: Instituto Nacional de Ecología, 98 pp
- Quesnelle, P.E., Fahrig L., Lindsay, K.E. **2013**. Effects of habitat loss, habitat configuration and matrix composition on declining wetland species. *Biol. Conserv.* 160, 200-8. <https://doi.org/10.1016/j.biocon.2013.01.020>
- Ramsar Convention on Wetlands. 2018. Global Wetland Outlook: State of the World's Wetlands and their Services to People. Gland, Switzerland: Ramsar Convention Secretariat.
- Rodríguez-Galiano, v.F., Ghimire, B., Rogan, J., Chica-Olmo, M., Rigol-Sanchez, J.P. **2012**. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS. J. Photogram*, 67, 93-104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Salitchev, K.A. **1979**. Cartografía, Editorial Pueblo y Educación, La Habana, 182 pp
- Simioni, JPD., Guaselli, L.A., De Oliveira, G.G., Ruiz, L.F.C., De Oliveira, G. 2020. A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation. *Wetland Ecol. Manage.*, 28:4, 577-594. DOI:[10.1007/s11273-020-09731-2](https://doi.org/10.1007/s11273-020-09731-2)
- Tiner, R.W. **1999**. Wetland indicators: A guide to wetland identification, delineation, classification, and mapping. CRC Press, Boca Raton, FL.
- Torbick, N., Ledoux, L., Salas, W., Zhao, M. **2016**. Regional mapping of plantation extent using multisensor imagery. *Remote Sens.*, 8(3), 236. <https://doi.org/10.3390/rs8030236>
- USDA. 2018. Field indicators of hydric soils in the United States. A guide for identifying and delineating hydric soils. Version 8.2, 55 pp
- Van Asselen, S., Verburg P.H., Vermaat J.E., Janse J.H. **2013**. Drivers of wetland conversion: a global meta-analysis. *PLoS ONE* 8, 1–13. <https://doi.org/10.1371/journal.pone.0081292>
- Ward, M.P., Semel B, Herkert J.R. **2010**. Identifying the ecological causes of long-term declines of wetland-dependent birds in an urbanizing landscape. *Biodiversity and Conservation* 19:3287–3300. <https://doi.org/10.1007/s10531-010-9893-y>
- Westlake, D.F., Kvet, J. Szczepanski, A. **1988**. Ecology of wetlands. IBP-Wetlands synthesis. Cambridge University Press, London, 568 pp



- Xu, H. **2006**. Modification of Normalized Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery. *Int. J. Remote Sens.*, 27, 3025-3033. <http://dx.doi.org/10.1080/01431160600589179>
- Zedler, J.B. **2003**. Wetlands at your service: reducing impacts of agriculture at the watershed scale. *Front. Ecol. Environ.* 1, 65-72



## ANEXO I

### Código R para obtención búfer áreas urbanas

```
library(sf)
library(readr)
library(dplyr)
library(tidyverse)

# Equal area grid to use as reference
grid1440 <- st_read('C:/Users/yanis/Documents/regions/1440gridV2/1440x456global_20200527.shp')

# New urban layer
urb = st_read('G:/My Drive/Humedales_Arg/areas_de_asentamientos_y_edificios_020105.shp')
list_urb = urb %>% st_set_geometry(NULL)

# Transform, calculate area and radio
urb_area = urb %>%
  st_transform(crs = st_crs(grid1440)) %>%
  st_make_valid() %>%
  mutate(area_m2 = st_area(geometry)) %>%
  mutate(radius = sqrt(area_m2/3.14)) %>%
  mutate(dist_buffer = radius/2) %>%
  mutate(gid=as.character(gid))

# Iterate through every polygon updating the buffer distance
urb_all = urb_area

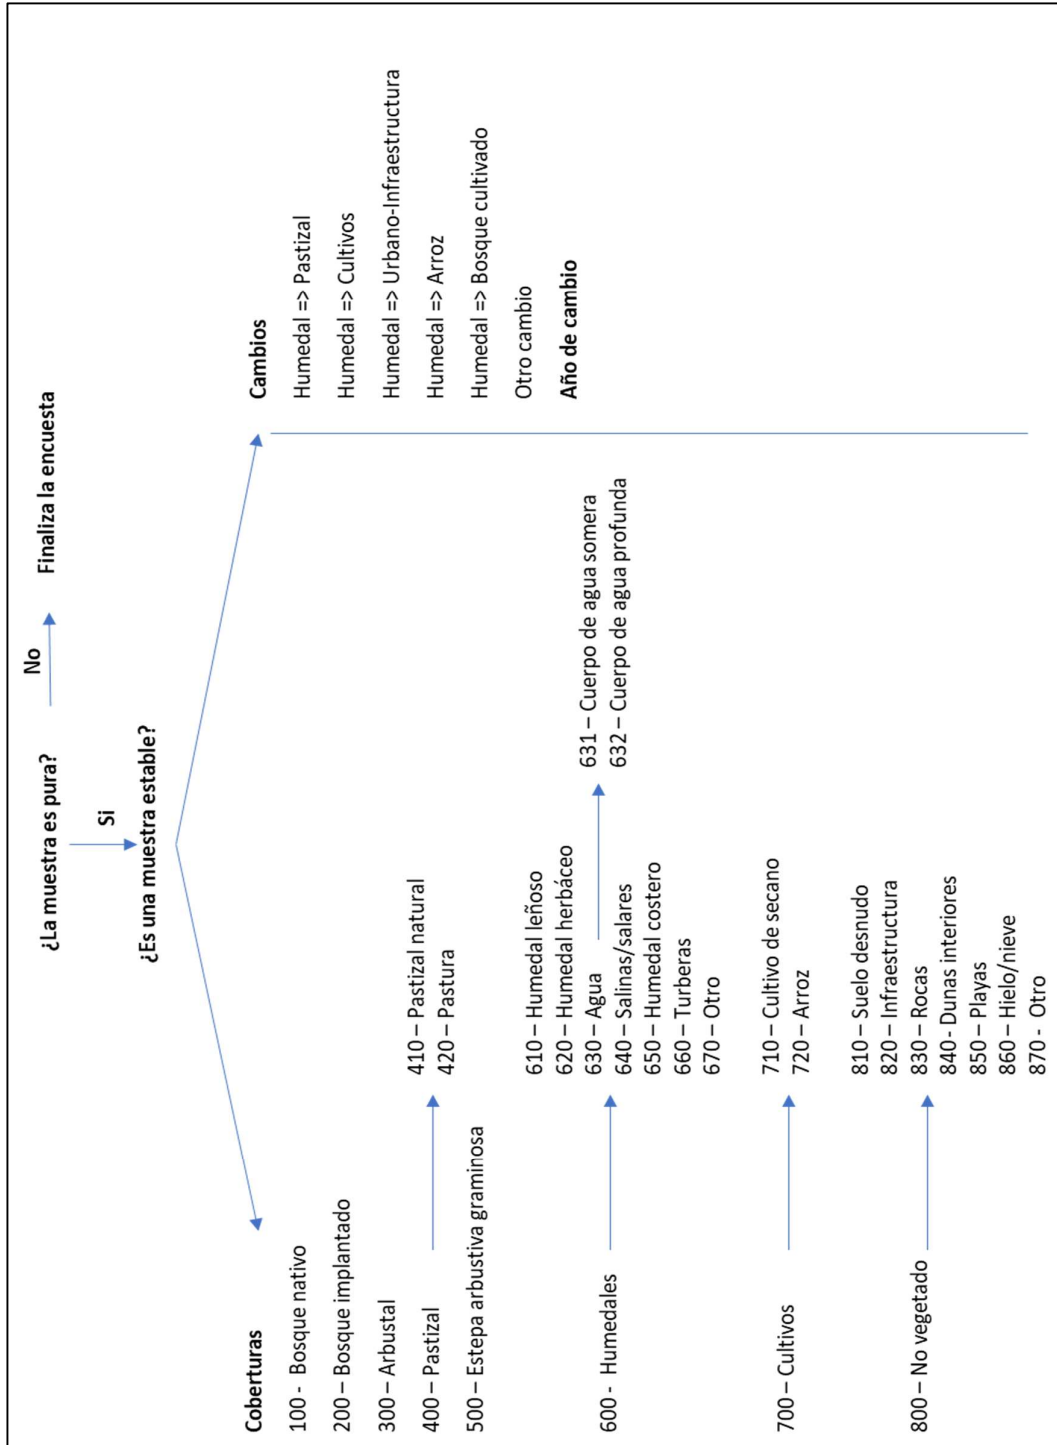
for (i in 1:length(list_urb$gid)){
  print(i);print(list_urb$fna[i])
  poly = urb_area[i,]
  dist = poly$dist_buffer
  poly_buf = st_buffer(poly,dist = dist)
  poly_buf$gid = paste(poly_buf$gid,'_b')
  urb_all = rbind(urb_all, poly_buf)
}

# Transform back and save
urb_all_latlon = urb_all %>%
  st_transform(urb_all,crs = st_crs(urb)) %>%
  filter(grepl('_b', gid))

write_sf(urb_all_latlon, 'G:/My Drive/Humedales_Arg/asentamientos_buffered.shp' )
```

## ANEXO II

Esquema y lista de códigos de la plantilla diseñada en Collect Earth para la determinación de humedales.







## ANEXO III – SCRIPT en GEE para determinación humedales en Argentina

```
var dic_regiones = {
'Regi3n Humedales Montanos Precordilleranos y Subandinos 1':['1'],
'Regi3n Humedales del Chaco 2':['2'],
'Subregi3n Vegas Lagunas Salares Puna 3a':['3a'],
'Subregi3n Vegas Lagunas Altoandinas 3b':['3b'],
'Regi3n Humedales Misioneros 4':['4'],
'Subregi3n Rios Esteros Ba3ados Lagunas R3o Paran3 5a':['5a'],
'Subregi3n Riachos Esteros Ba3ados Chaco H3medo 5b':['5b'],
'Subregi3n Malezales Tembladerles Arroyos Litorale3os 5c':['5c'],
'Subregi3n Rios Arroyos Valles Intermontanos 6a':['6a'],
'Subregi3n Arroyos Mallines Sierras Centrales 6b':['6b'],
'Subregi3n Salinas Depresi3n Central 6c':['6c'],
'Regi3n Humedales del Monte Central 7':['7'],
'Subregi3n Lagunas Pampa H3meda 8a':['8a'],
'Subregi3n Lagunas Salobres Pampa Interior 8b':['8b'],
'Subregi3n Playas Marismas Costa Bonaerense 9a':['9a'],
'Subregi3n Playa Marismas Costa Patagonia 9b':['9b'],
'Subregi3n Lagos Cursos Agua Mallines 10a':['10a'],
'Subregi3n Lagunas Vegas Patagonia 10b':['10b'],
'Subregi3n Mallines Turberas Patagonia Sur 10c':['10c'],
}
//Ajustes del Mapa
Map.setOptions({'HYBRID'});

//Construcci3n del paneles

var panel = ui.Panel([],ui.Panel.Layout.Flow('vertical'),{backgroundColor:'000000',position:'top-right'});
var panelmap = ui.Panel([],ui.Panel.Layout.Flow('vertical'),{backgroundColor:'white',position:'top-left',height:'600px'});
Map.widgets().set(1,panelmap);
panelmap.style().set({'shown',false});

//===== PREPROCESAMIENTO DE LOS DATOS =====//

//Selecci3n de la regi3n de inter3s (introducido como archivo vectorial)
var selectregion = ui.Select({
items: Object.keys(dic_regiones),
placeholder: 'Seleccione su Regi3n de Humedales',
onChange: function(select){

//Filtrar los datos de muestreo introducidos como archivo vectorial seleccionando los puros, estables y confiables

var filtro_puntos3 = puntos.filter(ee.Filter.inList('muestra_pu', ['true']));
var filtro_puntos2 = filtro_puntos3.filter(ee.Filter.inList('estabilida', ['true']));
var puntos_subregion = filtro_puntos2.filter(ee.Filter.inList('confiabili', ['true']));

//Reclasificaci3n de los puntos de muestreo
var recla_puntos = puntos_subregion.remap([100,200,300,410,420,500,610,620,630,640,660,670,710,720,810,820,830,840,850,860],
[1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18,19,20],'subcategor');

/*Numero y nombre de la clase seg3n recodificaci3n
Clase original      Clase recodificada      Nombre
100                 1                        Bosque nativo
200                 2                        Bosque cultivado
300                 3                        Arbustal
410                 4                        Pastizal natural
420                 5                        Pastura
500                 6                        Estepa arbustiva/arbustal bajo
610                 7                        Humedal le3oso
620                 8                        Humedal Herbac3ceo
630                 9                        Agua
640                 10                       Salinas/Salares
660                 11                       Turberas
670                 12                       Otro
710                 13                       Cultivo de secoano
720                 14                       Arroz
810                 15                       Suelo denudo
820                 16                       Infraestructura/urbano
830                 17                       Rocas
840                 18                       Dunas interiores
850                 19                       Dunas/Playas
860                 20                       Otro
*/

//Centrar y dibujar regi3n
var layer = ui.Map.Layer(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select[0]]])
.style({color:'orange',width:3,fillColor:'000000'}),{,select};
Map.centerObject(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]])),6);
Map.layers().set(0,layer);

//===== Clasificaci3n =====*/

//Funci3n que agrega una propiedad llamada "A3o_de_adq", para posteriormente filtrar los a3os necesarios
function data(img){
return img.set('A3o_de_adq', ee.Date(img.get('system:time_start')).format('YYYY'))
}

//Generar la m3scara para filtrar las nubes y urbanizaciones a la colecci3n landsat 5
function cloudmaskl5(img){
var calidad = img.select('BQA');
var nubes = calidad.eq(672);
//m3scara de Urbanizaciones
var maskurb = img.clip(Urbanizaciones).mask().not();
//unir m3scaras de Nubes y Urbanizaciones
var mask = nubes.and(maskurb);
return img.updateMask(mask);
};
```



```
var l5 = ee.ImageCollection("LANDSAT/LT05/C01/T1_TOA")
.filterBounds(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]])))
.filter(ee.Filter.calendarRange(2000,2012,'year'))
.filter(ee.Filter.calendarRange(10,4,'month'))
.filterMetadata('CLOUD_COVER','less_than',10)
.map(cloudmaskl5)
.map(function(img){

//renombrar las bandas de landsat 5 para que coincidan con l8 y generación de índices
var b3 = img.select('B2').rename('B3');
img = img.addBands(b3);
var b4 = img.select('B3').rename('B4');
img = img.addBands(b4);
var b5 = img.select('B4').rename('B5');
img = img.addBands(b5);
var b6 = img.select('B5').rename('B6');
img = img.addBands(b6);
var ndvi = img.normalizedDifference(['B4','B3']).rename('NDVI');
img = img.addBands(ndvi);
var ndwi1 = img.normalizedDifference(['B4','B5']).rename('NDWI1');
img = img.addBands(ndwi1);
var ndwi2 = img.normalizedDifference(['B4','B7']).rename('NDWI2');
img = img.addBands(ndwi2);
var mndwi1 = img.normalizedDifference(['B3','B5']).rename('MNDWI1');
img = img.addBands(mndwi1);
var mndwi2 = img.normalizedDifference(['B3','B7']).rename('MNDWI2');
img = img.addBands(mndwi2);
var savi = img.expression('((nir-red)/(nir+red+0.5))*1.5', {
  nir : img.select('B4'),
  red : img.select('B3')
}).rename('SAVI');
img = img.addBands(savi);
return img.select(['B3','B4','B5','B6','B7','NDVI', 'SAVI','MNDWI1','MNDWI2','NDWI1','NDWI2']);
});

//Generar la máscara para filtrar las nubes y urbanizaciones a la colección landsat 8
function cloudmaskl8(img){
  var calidad = img.select('BQA');
  var nubes = calidad.eq(2720);
  //máscara de Urbanizaciones
  var maskurb = img.clip(Urbanizaciones).mask().not();
  //unir máscaras de Nubes y Urbanizaciones
  var mask = nubes.and(maskurb);
  return img.updateMask(mask);
};

var l8 = ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
.filterBounds(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]])))
.filter(ee.Filter.calendarRange(2014,2021,'year'))
.filter(ee.Filter.calendarRange(10,4,'month'))
.filterMetadata('CLOUD_COVER','less_than',10)
.map(cloudmaskl8)
.map(function(img){
  var ndvi = img.normalizedDifference(['B5','B4']).rename('NDVI');
  img = img.addBands(ndvi);
  var ndwi1 = img.normalizedDifference(['B5','B6']).rename('NDWI1');
  img = img.addBands(ndwi1);
  var ndwi2 = img.normalizedDifference(['B5','B7']).rename('NDWI2');
  img = img.addBands(ndwi2);
  var mndwi1 = img.normalizedDifference(['B3','B6']).rename('MNDWI1');
  img = img.addBands(mndwi1);
  var mndwi2 = img.normalizedDifference(['B3','B7']).rename('MNDWI2');
  img = img.addBands(mndwi2);
  var savi = img.expression('((nir-red)/(nir+red+0.5))*1.5', {
    nir : img.select('B5'),
    red : img.select('B4')
  }).rename('SAVI');
  img = img.addBands(savi);
return img.select(['B3','B4','B5','B6','B7','NDVI', 'SAVI','MNDWI1','MNDWI2','NDWI1','NDWI2']);
});

//Unir colecciones de ambos satélites
var mergeColeccion = l5.merge(l8)
print('Colección', mergeColeccion)
```



```
//Construir estadísticos para la colección
var mediana = mergeColeccion.reduce(ee.Reducer.median());
var media = mergeColeccion.reduce(ee.Reducer.mean());
var desvio = mergeColeccion.reduce(ee.Reducer.stdDev());

//Inclusión del JRC
var JRC = ee.Image("JRC/GSW1_3/GlobalSurfaceWater").unmask().clip(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]])).float());

//Inclusión del DEM_30m e índices topográficos derivados del mismo
var TWI = TWI_30.map(function(img){return img.rename('TWI')});
var DEM = DEM_30.map(function(img){return img.rename('DEM')});
var TPI = TPI_30.map(function(img){return img.rename('TPI')});

//Construcción del Stack
var stack = media.addBands(mediana).addBands(desvio)
.addBands(JRC.select('occurrence', 'seasonality',
'recurrence')).addBands(TWI.mosaic()).addBands(DEM.mosaic()).addBands(TPI.mosaic());

//Lista contenedora de bandas seleccionadas para el stack
var lista = ee.List([])

var bandas = ui.data.ActiveList(['B3_mean', 'B3_median', 'B3_stdDev', 'B4_mean', 'B4_median', 'B4_stdDev',
'B5_mean', 'B5_median', 'B5_stdDev', 'B6_mean', 'B6_median', 'B6_stdDev', 'B7_mean',
'B7_median', 'B7_stdDev', 'NDVI_mean', 'NDVI_median', 'NDVI_stdDev', 'NDWI1_mean', 'NDWI1_median',
'NDWI1_stdDev', 'NDWI2_mean', 'NDWI2_median', 'NDWI2_stdDev', 'SAVI_mean', 'SAVI_median', 'SAVI_stdDev',
'MNDWI1_mean', 'MNDWI1_median', 'MNDWI1_stdDev', 'MNDWI2_mean', 'MNDWI2_median', 'MNDWI2_stdDev',
'occurrence', 'seasonality', 'recurrence', 'TWI', 'DEM', 'TPI']);

//Función para generar el cuadro con las bandas y seleccionarlas mediante un check
var check = bandas.forEach(function(x){
var incheck = ui.Checkbox({label: x,value: false,style:{fontSize:'12px',color:'black',backgroundColor:'white'}});
incheck.onChange(function(checked){
if(checked===true){
lista = lista.add(x);
}else{
lista = lista.remove(x);
}
})
panelmap.widgets().set(0,ui.Label('Seleccione las Bandas para el stack'+'\n', {fontSize: '12px',fontWeight : 'bold'}));
panelmap.widgets().set(1,ui.Label('Presione ok, al finalizar',{fontSize: '12px',fontWeight : 'bold'}));
panelmap.widgets().set(41,incheck);
panelmap.style().set('shown',true);
})

var listaelegida = ui.Button({label:'OK', onClick:function(i){
var stackcontruido = stack.select(ee.List(lista.distinct()))
print(stackcontruido)
var layer1 = ui.Map.Layer(stackcontruido.clip(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]]))),
{'Mosaico'})
Map.layers().set(1,layer1)

/*Gráfico de NDVI de la región*/
var graRegion = ui.Chart.image.series(15.merge(18).select('NDVI'), region.filter(ee.Filter.inList('Region_num',
[dic_regiones[select][0]])),ee.Reducer.mean(),5000)
print('Dinámica del NDVI', graRegion)

/*muestras de entrenamiento*/
var muestras = stackcontruido.sampleRegions({collection:recla_puntos,properties:['subcategor'], scale:30, tileSize:16,
geometries:true})

//Gráfico de muestras por clase
var chartmuestras = ui.Chart.feature.histogram(recla_puntos, 'subcateg_1')
.setChartType('ColumnChart')
.setOptions({
title: 'Distribución de muestras por clase',
legend: {position: 'none'},
hAxis: {title: 'Clases'},
vAxis: {title: 'Frecuencia'},
});
print('Histograma de Clases', chartmuestras)
```





```
/*Particionar muestras de entrenamiento del clasificador y para la validación*/
var random = muestras.randomColumn()
var entrenamiento = random.filter(ee.Filter.lte('random',0.7))
var validacion = random.filter(ee.Filter.gt('random',0.7))

//Imprimir las variables para analizar el número de datos de entrenamiento y de prueba se utilizan
print('Número de muestras totales =', random.aggregate_count('.all'));
print('Datos de entrenamiento =', entrenamiento.aggregate_count('.all'));
print('Datos de validación =', validacion.aggregate_count('.all'));

/*===== CLASIFICACIÓN MEDIANTE RANDOM FOREST =====*/

/*===== CLASIFICACIÓN DETERMINISTICA =====*/
var clasificador = ee.Classifier.smileRandomForest({numberOfTrees:100, variablesPerSplit:5,seed:5}).train(entrenamiento,
'subcategor', ee.List(lista.distinct()))

//Método explain (muestra la importancia relativa de las variables que se utilizan)
print(clasificador.explain())

//Clasificar
var clasificacion = stackcontruido.classify(clasificador)

Map.addLayer(clasificacion.clip(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0])))),{palette:
['199702','b82212','9b6640','fbff00','d6b882','978458','5c05d0','9429c0','3921ff','f3f3f3','d97eff','e9b4ff','ff7d4b',
'ff9583','ff2964','898989','585858','8f9938','cbd66e','454545'], min:1, max:20},'Clasificación Determinística')

//Validación de la clasificación (solo para la determinística)
var validac_et = stackcontruido.sampleRegions({
collection:validacion,
properties:['subcategor'],
scale:30,
tileScale: 8
});
var valida_matrix = validac_et.classify(clasificador);

//Matriz de confusión
var testAccuracy = valida_matrix.errorMatrix('subcategor', 'classification');
print('Matriz de confusión: ', testAccuracy);
print('Exactitud global: ', testAccuracy.accuracy());
print('Errores de comisión', testAccuracy.producersAccuracy());
print('Errores de omisión',testAccuracy.consumersAccuracy());

/*===== CLASIFICACIÓN PROBABILISTICA =====*/

//Recodificación de los datos muestrales a formato binario
var recod = entrenamiento.remap([1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18,19,20],[0,0,0,0,0,0,1,1,1,1,1,1,0,
0,0,0,0,0,0,0],'subcategor');

var clasifi_prob = ee.Classifier.smileRandomForest({numberOfTrees:100, variablesPerSplit: 5, seed: 5}).train(recod, 'subcategor',
ee.List(lista.distinct())).setOutputMode('PROBABILITY')

var clasificacion_prob = stackcontruido.classify(clasifi_prob)

Map.addLayer(clasificacion_prob.clip(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0])))), {min:0, max:1,
palette: ['d63000', 'faff00', '00ff08', '00cfff', '2b83ba']}, 'Clasificación Probabilística')

/*===== Exportar, descargar e imprimir información=====*/

//Exportar la clasificación
Export.image.toDrive({
image: clasificacion.clip(region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0])))),
description:'Clasificación: Región ' + dic_regiones[select][0], folder: 'Clasificaciones',
region: region.filter(ee.Filter.inList('Region_num', [dic_regiones[select][0]))), scale:30, maxPixels:1e13});
Map.widgets().remove(panelmap);

//Descargar muestras de entrenamiento
var url = muestras.getDownloadURL({
filename: 'CSV_Muestras'+ ' Region: '+dic_regiones[select][0],
format: 'CSV',
});
var ExportingLinks=ui.Label('Descargar Muestras de entrenamiento', {fontWeight:'bold',backgroundColor:'0000000',fontSize:'15px'})
.setUrl(url);
print('Valores de las variables', ExportingLinks)
```





```
//Gráfico de importancia de las variables
var variable_importancia = ee.Feature(null, ee.Dictionary(clasificador.explain()).get('importance'));
var chartimportancia =ui.Chart.feature.byProperty(variable_importancia)
.setChartType('ColumnChart')
.setOptions({
  title: 'Importancia de los predictores Random Forest',
  legend: {position: 'none'},
  hAxis: {title: 'Bandas'},
  vAxis: {title: 'Importancia'}
});

print('Importancia de cada variable', chartimportancia);

/*===== Añadir leyenda al mapa =====*/

// ubicación de la leyenda en el mapa
var legend = ui.Panel({
  style: {
    position: 'bottom-left',
    padding: '8px 20px',
    backgroundColor: 'white',
    height:'480px'
  }
});

// Crear la leyenda
var legendTitle = ui.Label({
  value: 'Leyenda',
  style: {
    fontWeight: 'bold',
    fontSize: '13px',
    margin: '0 0 8px 0',
    padding: '30',
    backgroundColor: '00000000'
  }
});

// Añadir el título al panel
legend.add(legendTitle);
// Estilos de la primera columna de la leyenda
var makeRow = function(color, name) {

  // etiquetas de los colores
  var colorBox = ui.Label({
    style: {
      backgroundColor: '#' + color,
      // usar padding para establecer márgenes y anchos
      padding: '6px',
      margin: '0 0 4px 0'
    }
  });

  // crear etiqueta con descripción del texto
  var description = ui.Label({
    value: name,
    style: {margin: '0 0 6px 9px', backgroundColor: '00000000', fontSize:'11px', width: 3}
  });

  // Devolver el panel
  return ui.Panel({
    widgets: [colorBox, description],
    layout: ui.Panel.Layout.Flow('horizontal'),
    style: {backgroundColor: '00000000', color: 'black'}
  });
};

// paleta de referencias
var palette2 =['199702','b82212','9b6640','fbff00','d6b882','978458','5c05d0','9429c0','3921ff','f3f3f3','d97eff','e9b4ff','ff7d4b',
'ff9583','ff2964','898989','585858','8f9938','cbd66e','454545'];

// nombre de la leyenda
var names2 = ['Bosque nativo', 'Bosque cultivado', 'Arbustal','Pastizal natural', 'Pastura','Estepa arbt. gram./ Arbustal bajo',
'Humedal leñoso', 'Humedal herbáceo', 'Agua', 'Salinas/Salares', 'Turberas', 'Otro', 'Cultivo secano', 'Arroz', 'Suelo desnudo',
'Infraestructura/urbano','Rocas', 'Dunas interiores', 'Dunas/Playas', 'Otro'];
```



```
// añadir color y nombres
for (var j = 0; j < 20; j++) {
  legend.add(makeRow(palette2[j], names2[j]));
}

Map.widgets().set(4, legend);

var abriretiq = ui.Button('>', function(){
  legend.style().set('shown', true);
  abriretiq.style().set('shown', false);
}, null, {position: 'bottom-left'});

Map.widgets().set(3, abriretiq);

abriretiq.style().set('shown', false);
var ocultaretiq = ui.Button('v', onClick: function(){
  abriretiq.style().set('shown', true);
  legend.style().set('shown', false);
}, style: {position: 'bottom-left'});
legend.add(ocultaretiq);
}, style: {}));

panelmap.widgets().set(41, listaelegida);

panel.style().set('shown', false);
}
});
panel.widgets().set(0, selectregion);
Map.add(panel);
```



## ANEXO IV

### Planilla diseñada para relevamiento de información de campo

#Planilla:	Propietario:	WayPoint	Lat:	
Provincia	Sitio:		Long:	
Fecha: Responsable:	Tipo de humedal: Pendiente: V U — —	Condición (seco, anegamiento, inundación)	Foto: si/no, #:	
Emplazamiento geomorfológico/fisiográfico	Uso actual:	Intensidad uso:	Pastoreo:	
Suelo	CE: pH: Color: Moteados	0-10	10-30	30-50
Vegetación (tipo, spp dominantes)		Cobertura (%): Especies invasoras:		
Agua	Superficial: Profunda: Subsuperficial	Signos de humedad (cm): Napa freática (cm):		
Síntomas de degradación	Erosión hídrica: Salinización (% sales superficiales): Compactación:	Cárcavas: ausentes - suaves – moderadas – severas. 0-25      25- 50      50-75      75-100  Densidad aparente		



OBSERVACIONES: describir el perfil del gradiente ambiental e indicar puntos de muestreo dentro del gradiente.

Manejo actual: ganadería (ovina, bovina, caprina).

Intensidad de uso: alta, media baja carga.

Pastoreo: continuo o rotativo

Suelo: Dependiendo de las posibilidades, se tomarán 3 muestras compuestas de suelo hasta alcanzar el metro de profundidad o puntual a 0-20 cm de profundidad. En laboratorio se analizará MOS, pH y CE.


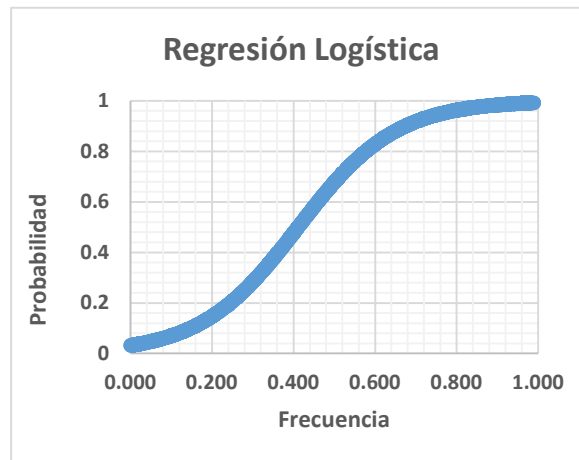
Densidad aparente: con muestreador de suelo no perturbado de volumen conocido (Kopeki) o penetrómetro, de poder adquirirse.



## ANEXO V

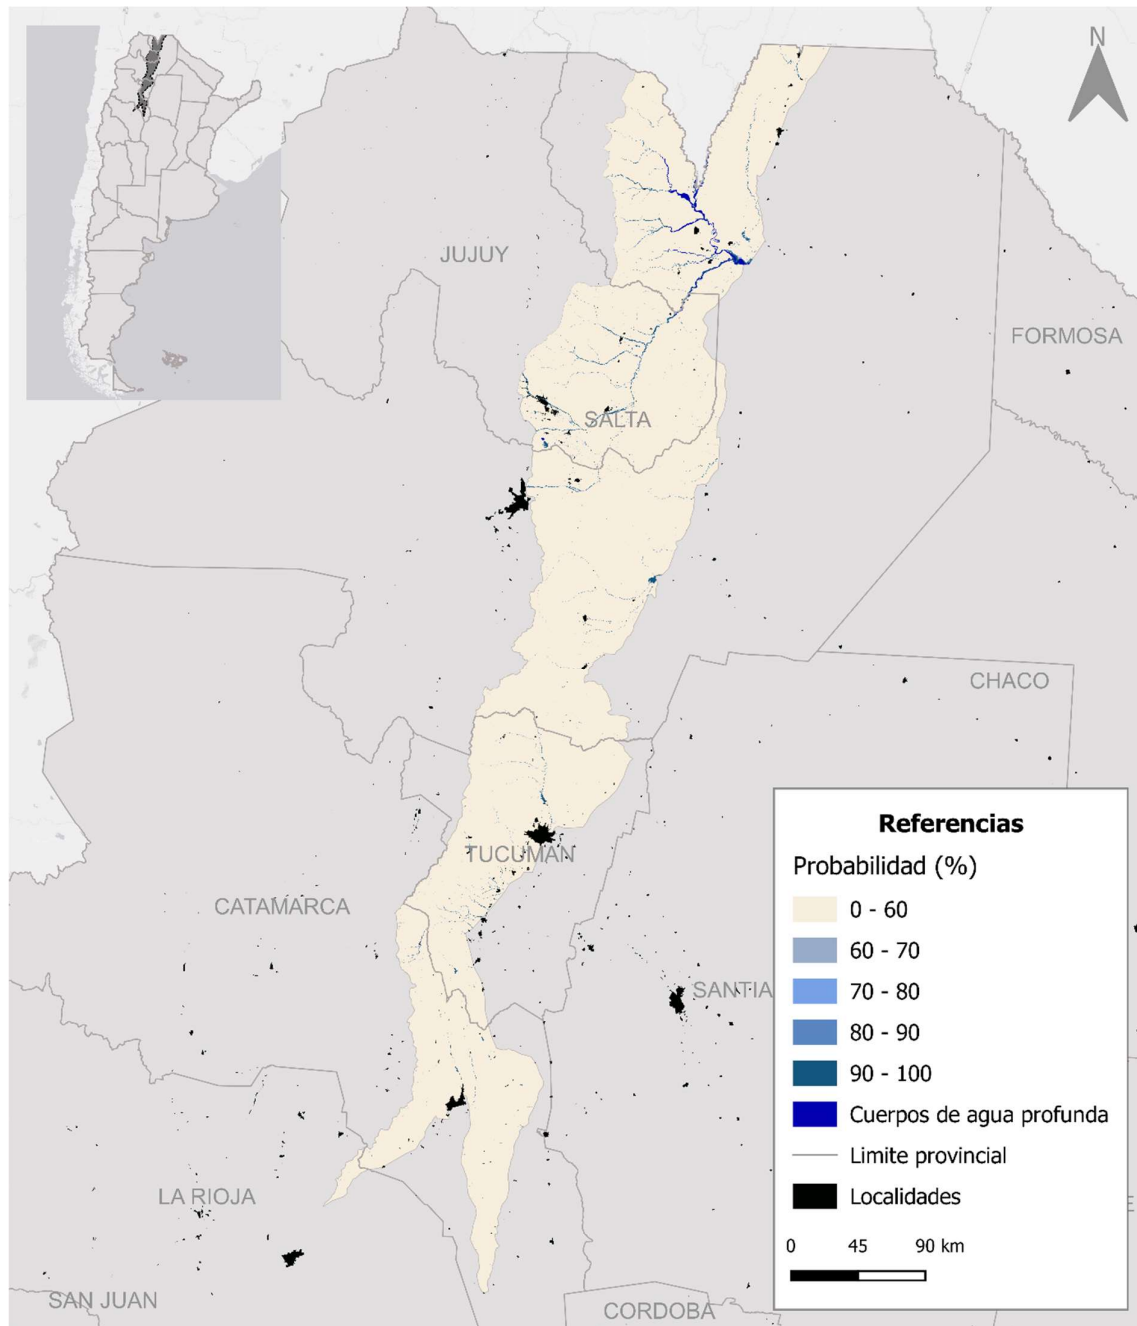
### Resultados del análisis de regresión

	coeff b	s.e.		
Intercept	-3.4356912	0.09748888		
Frecuencia	8.34799746	0.21112643		
Chi-Sq	3642.20268		Covariance Matrix	
df	1		0.00950408	-0.01798692
p-value	0		-0.01798692	0.04457437
alpha	0.05			
sig	yes			
Classification Table				
	Suc-Obs	Fail-Obs		
Suc-Pred	2158	268	2426	
Fail-Pred	286	2074	2360	
	2444	2342	4786	
Accuracy	0.88297872	0.88556789	0.88424572	
Cutoff	0.5			

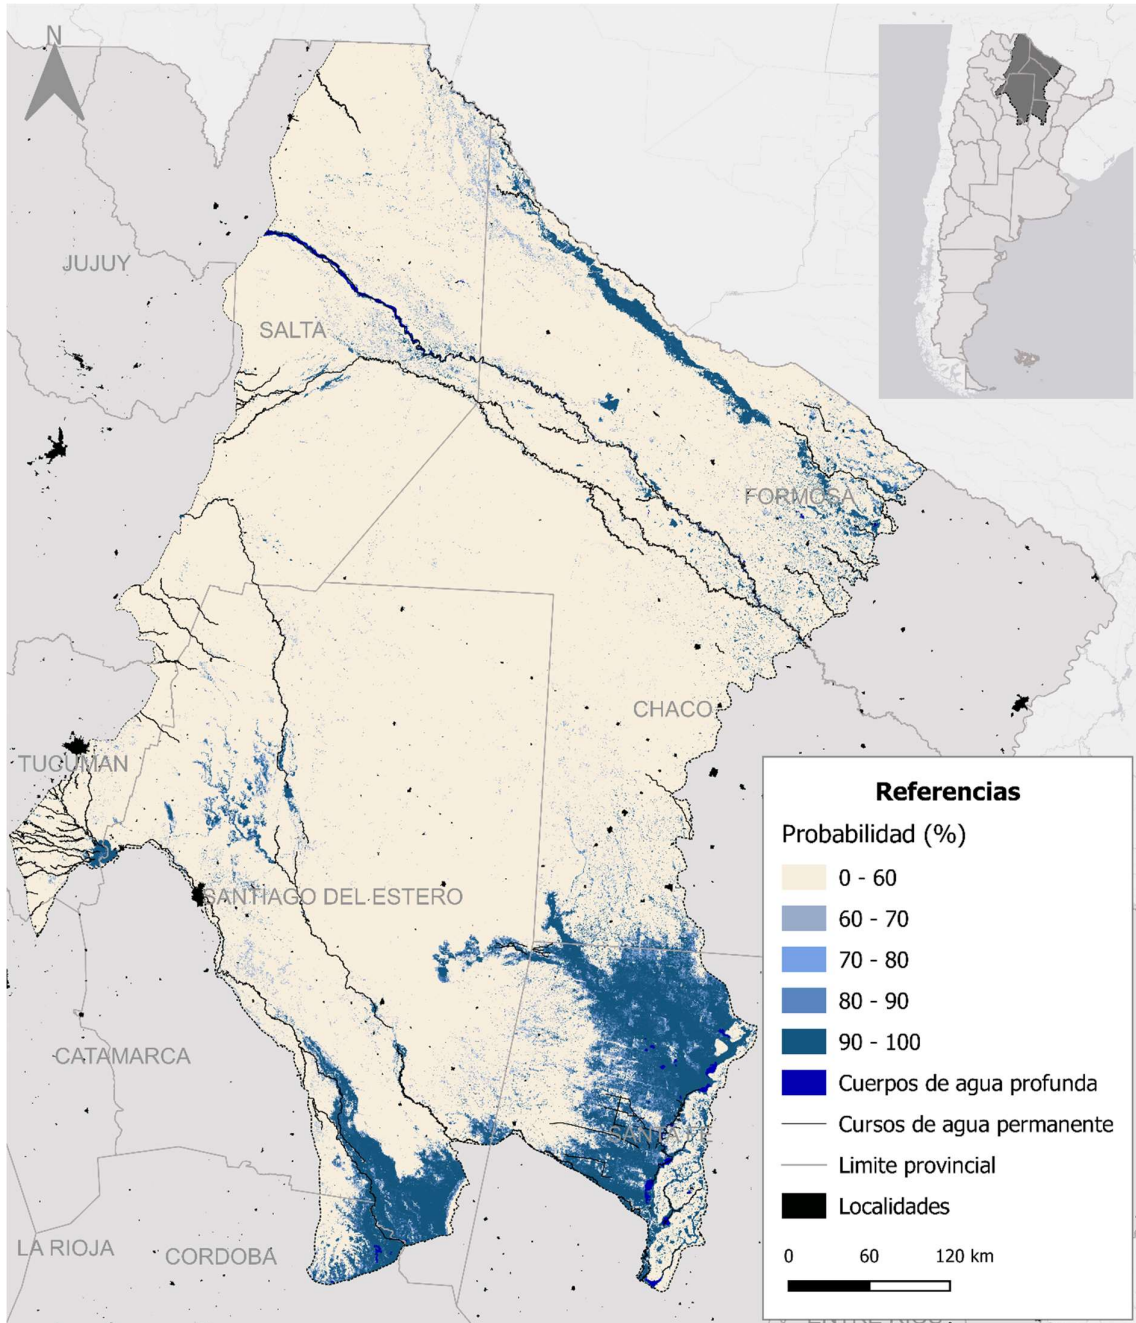


## ANEXO VI - MAPAS

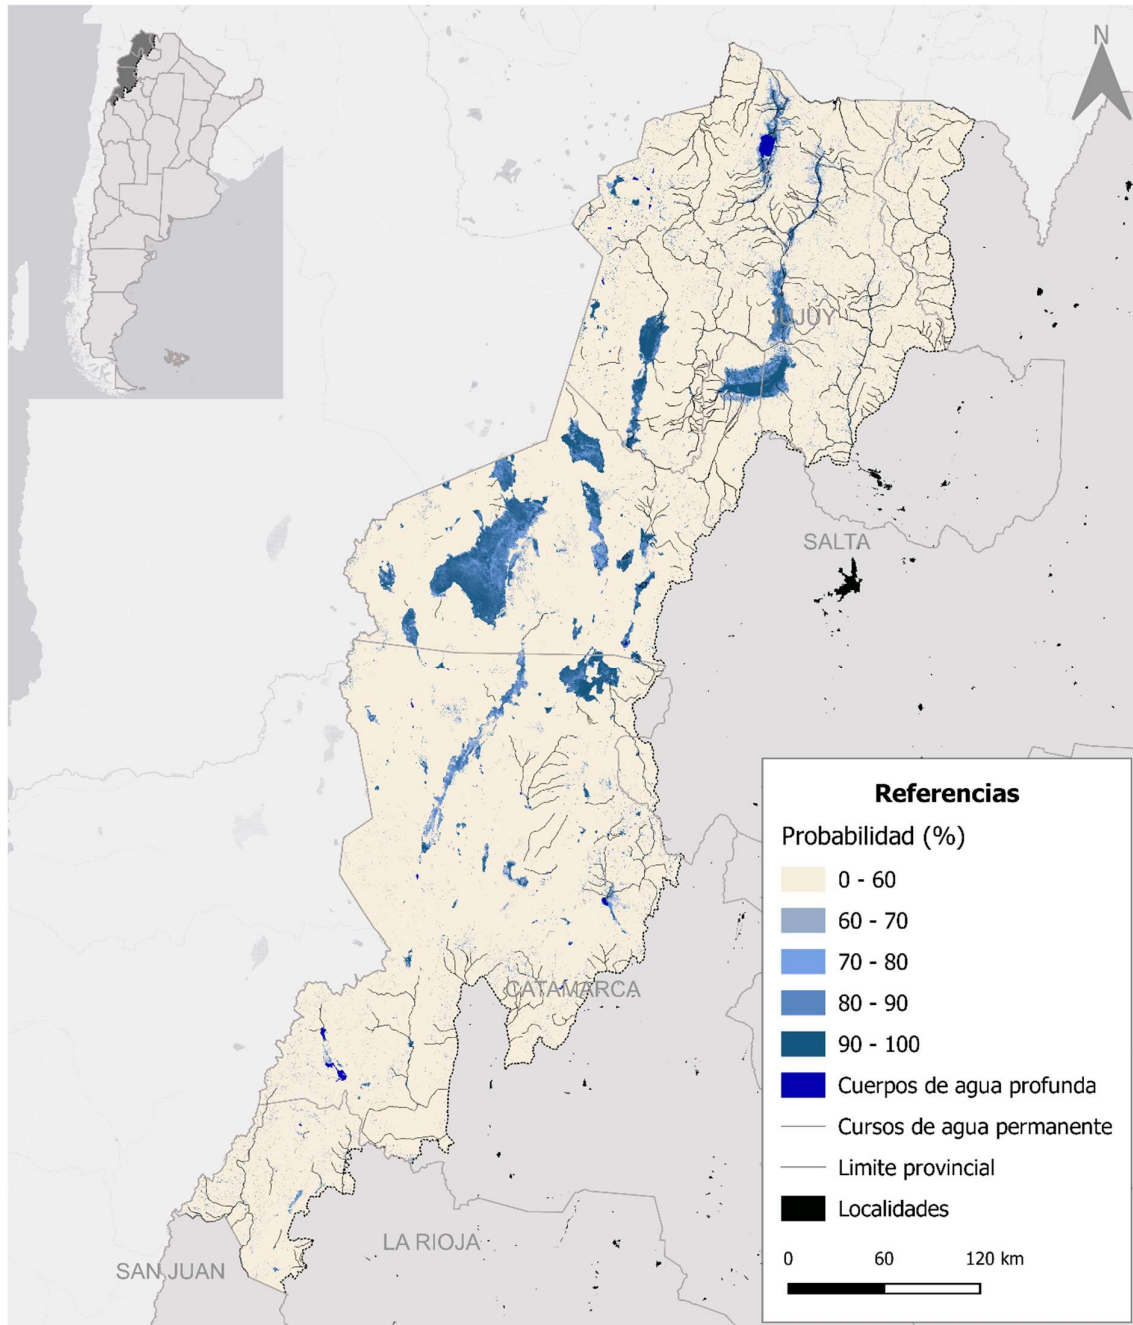
Mapa de probabilidad de humedales de la Región *Humedales montanos precordilleranos y subandinos*. Superficie total 736 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 81; 80-90% = 114; > 90% = 541 km<sup>2</sup>.



Mapa de probabilidad de humedales de la Región *Humedales del Chaco*. Superficie total 36.858 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 3567; 80-90% = 4286; > 90% = 29.005 km<sup>2</sup>.

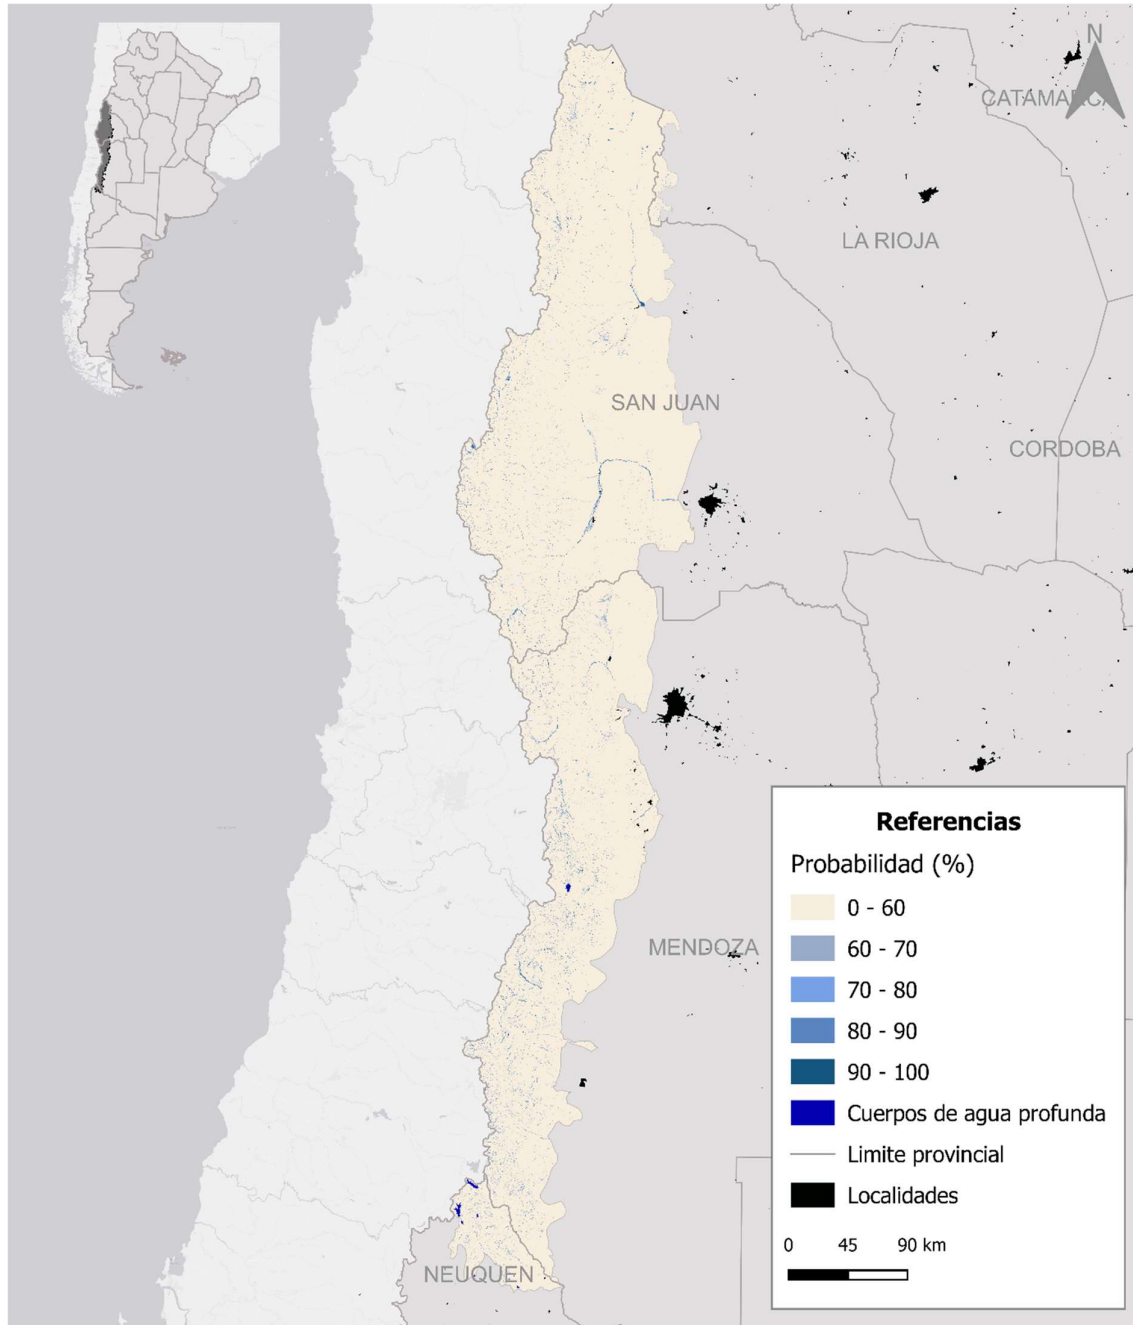


Mapa de probabilidad de humedales de la Subregión *Vegas, lagunas y salares de la Puna*. Superficie total 10.491 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 1.492; 80-90% = 2.760; > 90% = 6.239 km<sup>2</sup>.

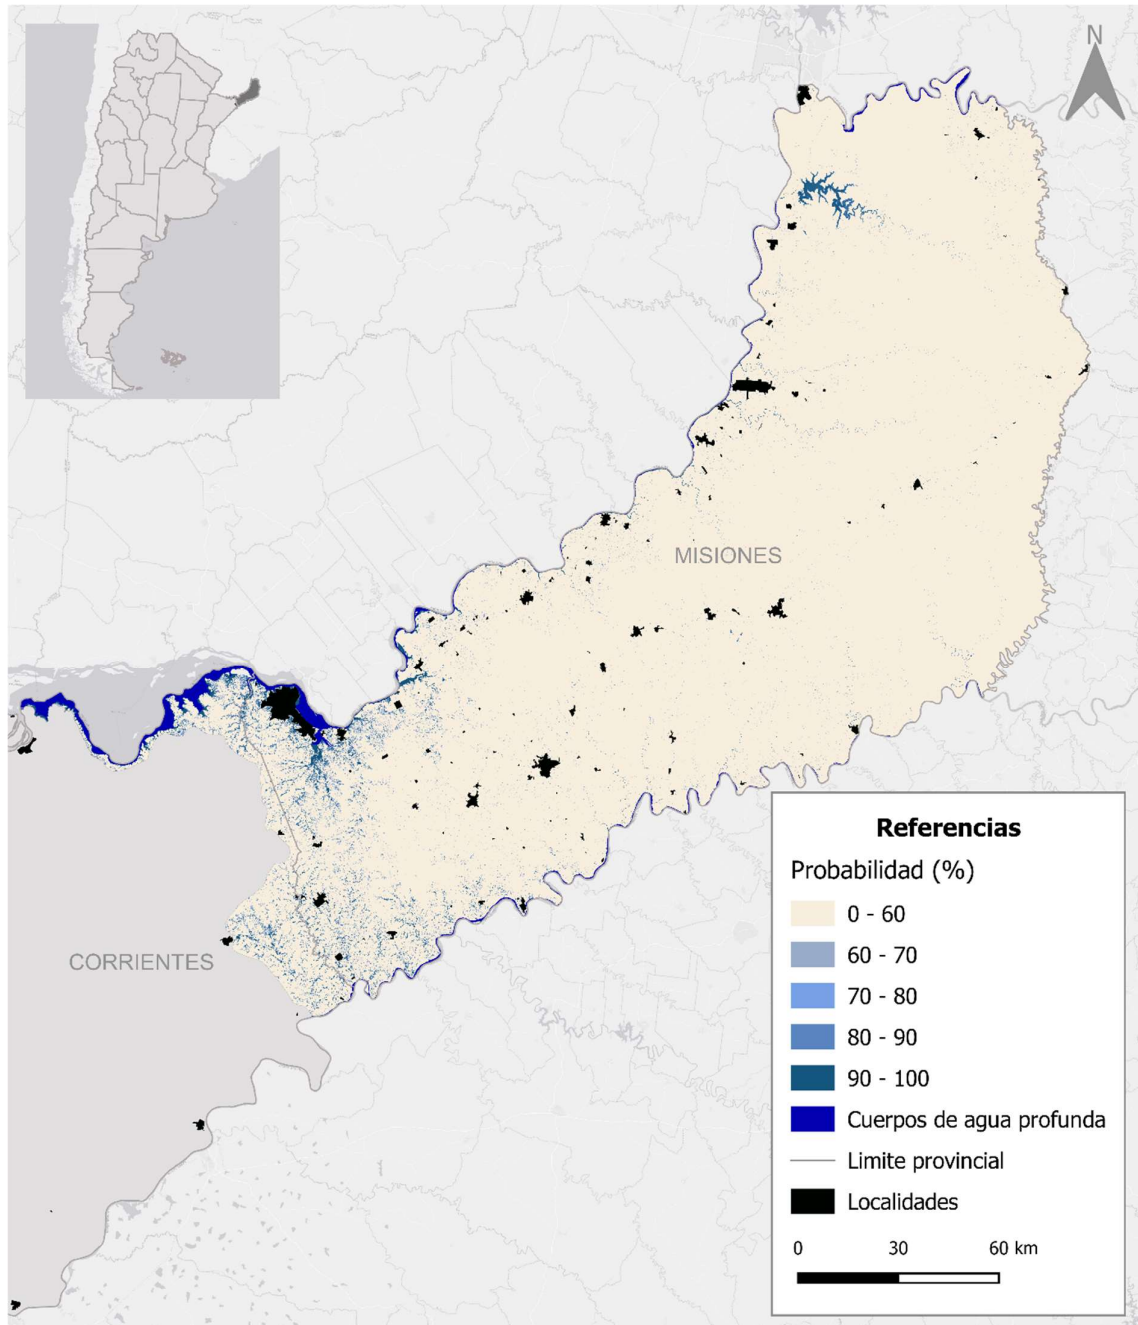




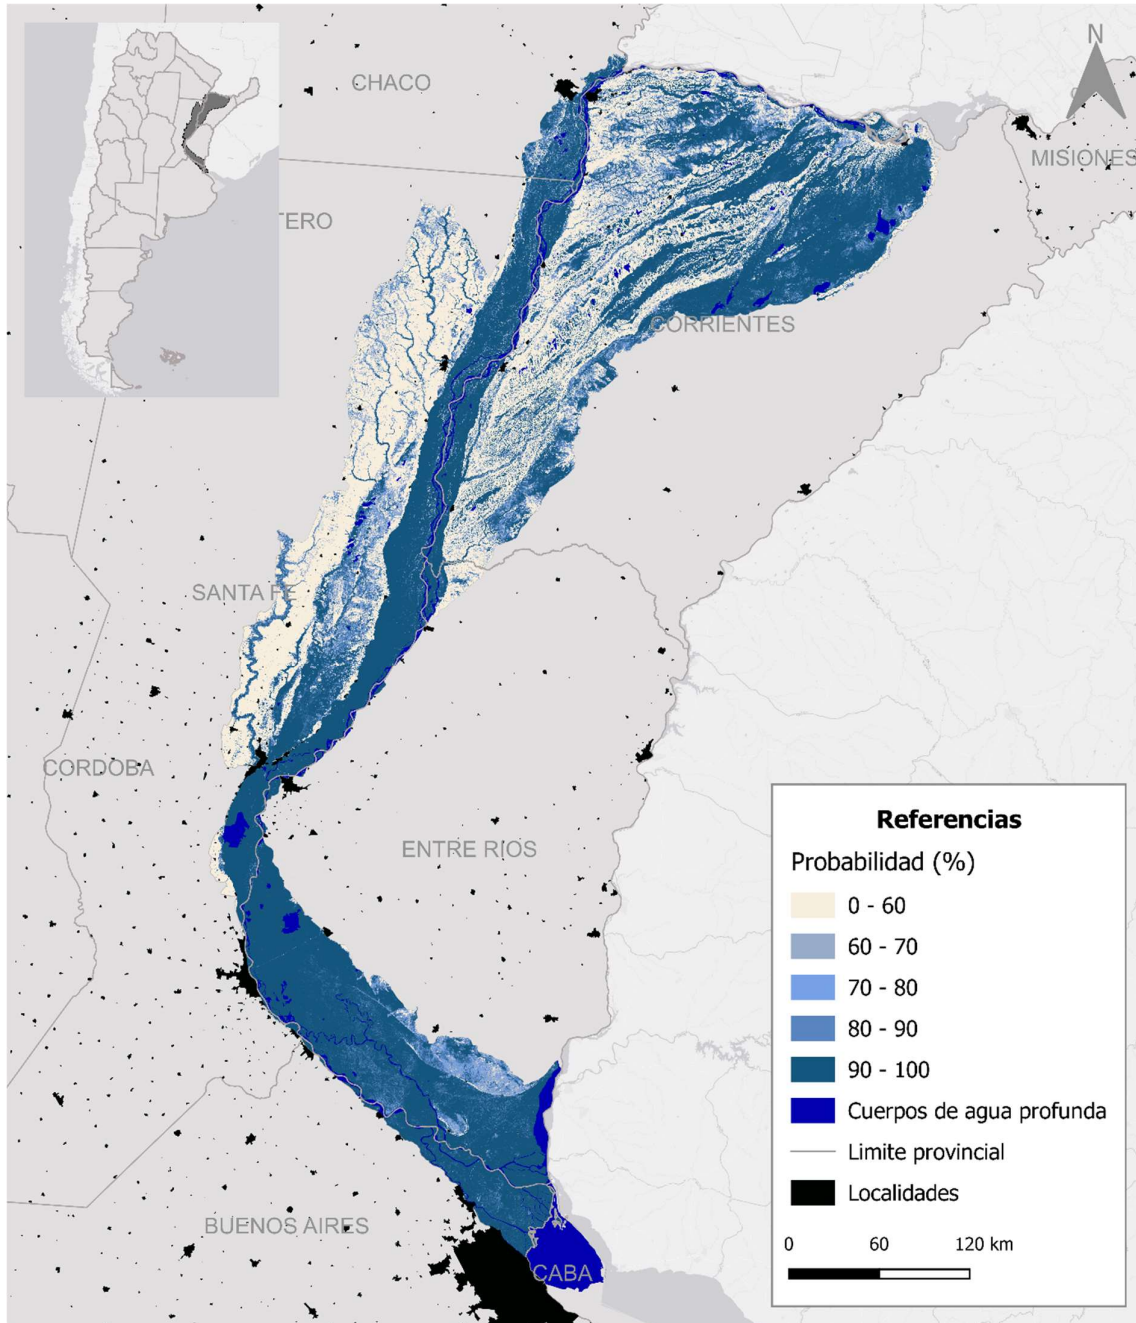
Mapa de probabilidad de humedales de la Subregión *Vegas, lagunas altoandinas*. Superficie total 12663 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 640; 80-90% = 580; > 90% = 443 km<sup>2</sup>.



Mapa de probabilidad de humedales de la Región *Humedales misioneros*. Superficie total 855 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 159; 80-90% = 195; > 90% = 501 km<sup>2</sup>.

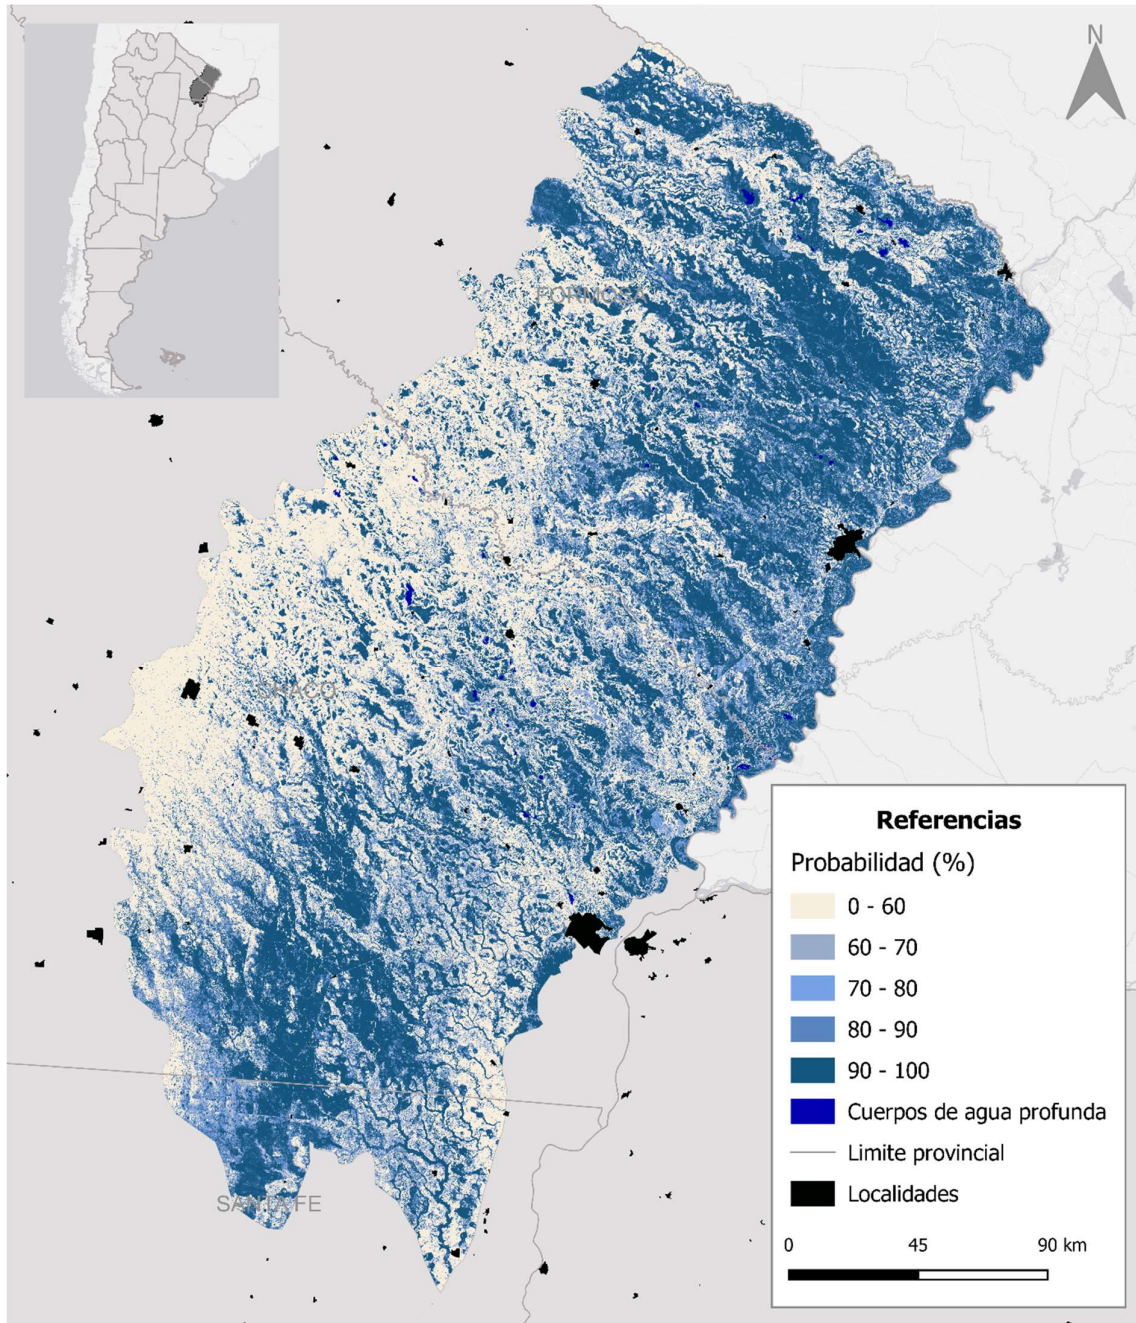


Mapa de probabilidad de humedales de la Subregión *Ríos, esteros, bañados y lagunas del río Paraná*. Superficie total 63.946 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 2.462; 80-90% = 4.247; > 90% = 57.237 km<sup>2</sup>.

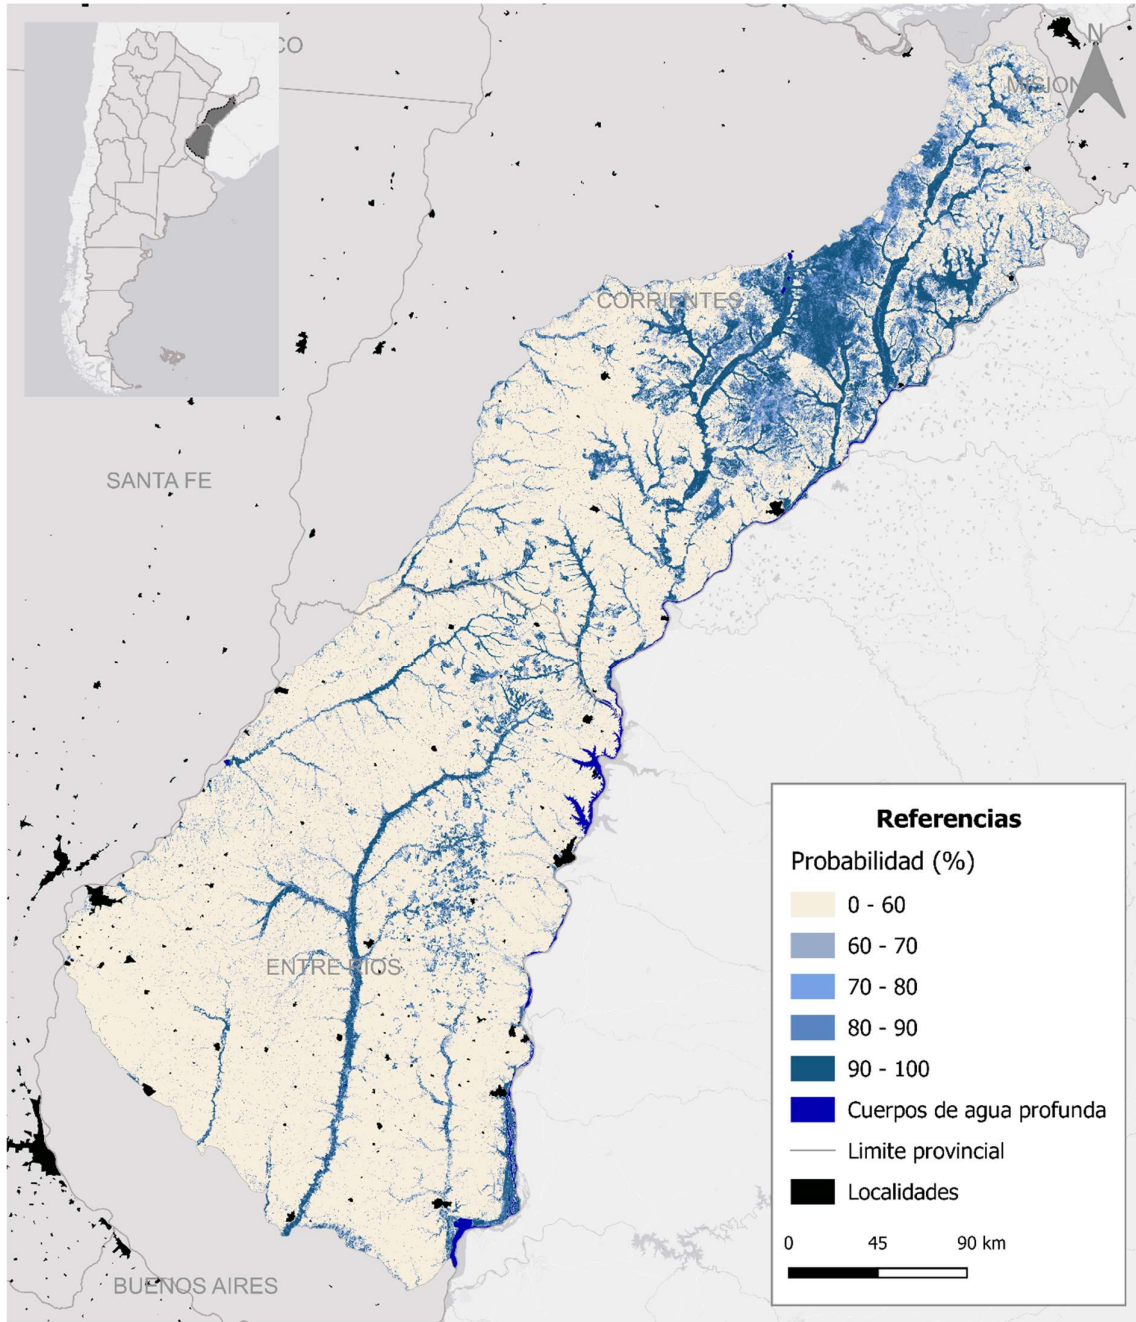




Mapa de probabilidad de humedales de la Subregión *Riachos, esteros y bañados del Chaco Húmedo*. Superficie total 38.252 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 3.931; 80-90% = 6.065; > 90% = 28.256 km<sup>2</sup>.

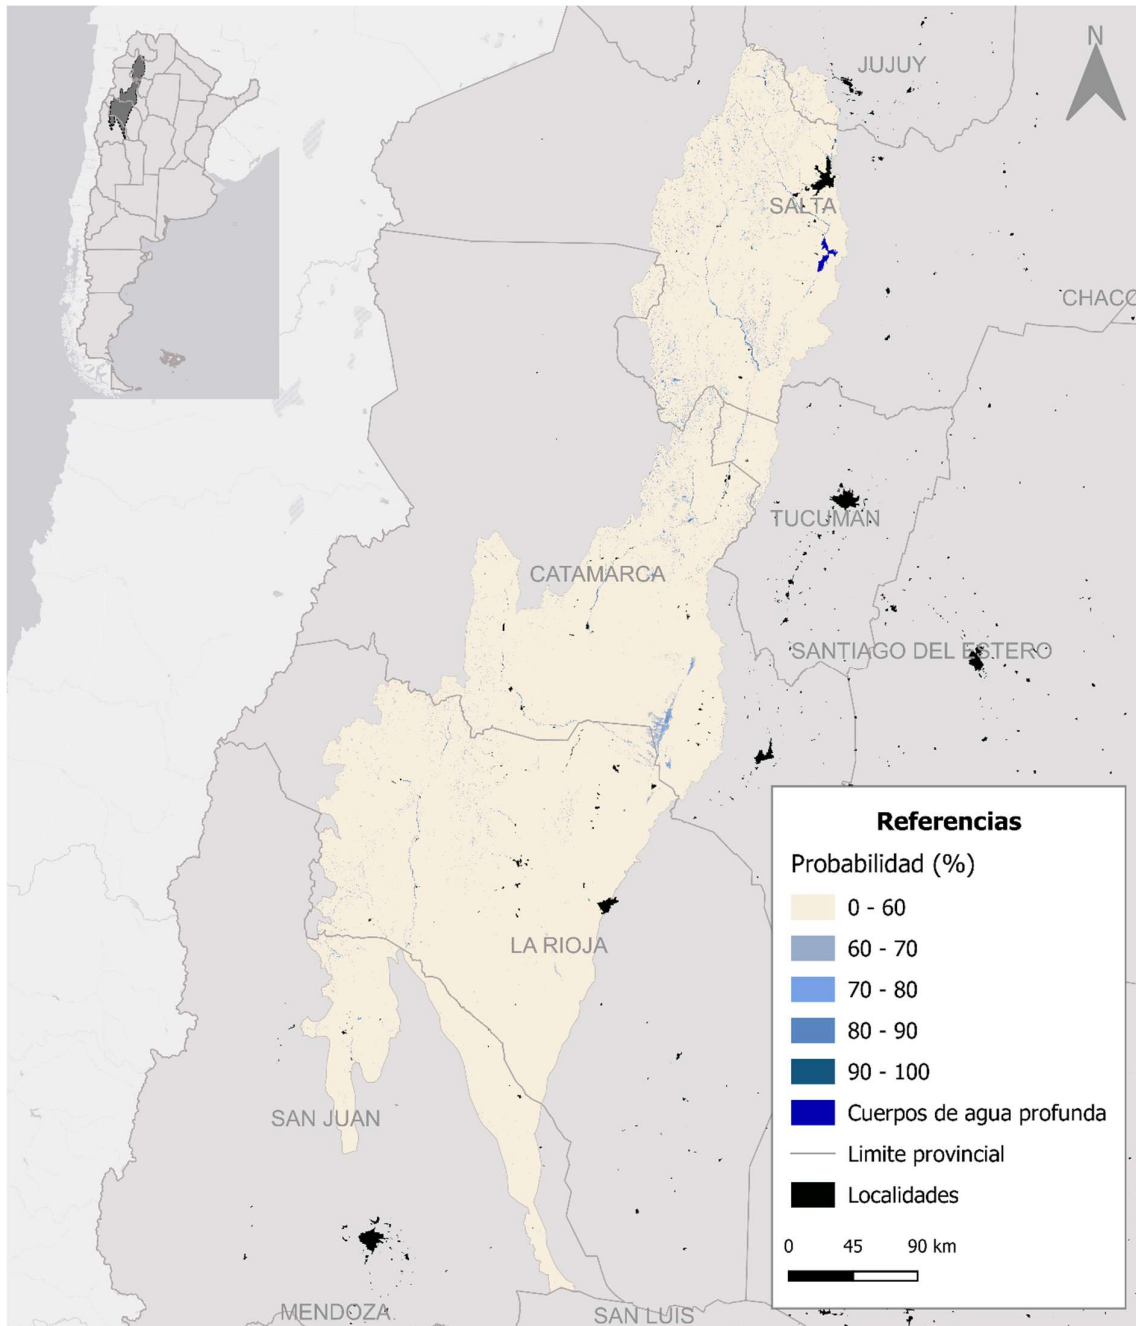


Mapa de probabilidad de humedales de la Subregión *Malezales, tembladerales y arroyos litoraleños*. Superficie total 19.257 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 3.013; 80-90% = 4.012; > 90% = 12.232 km<sup>2</sup>.

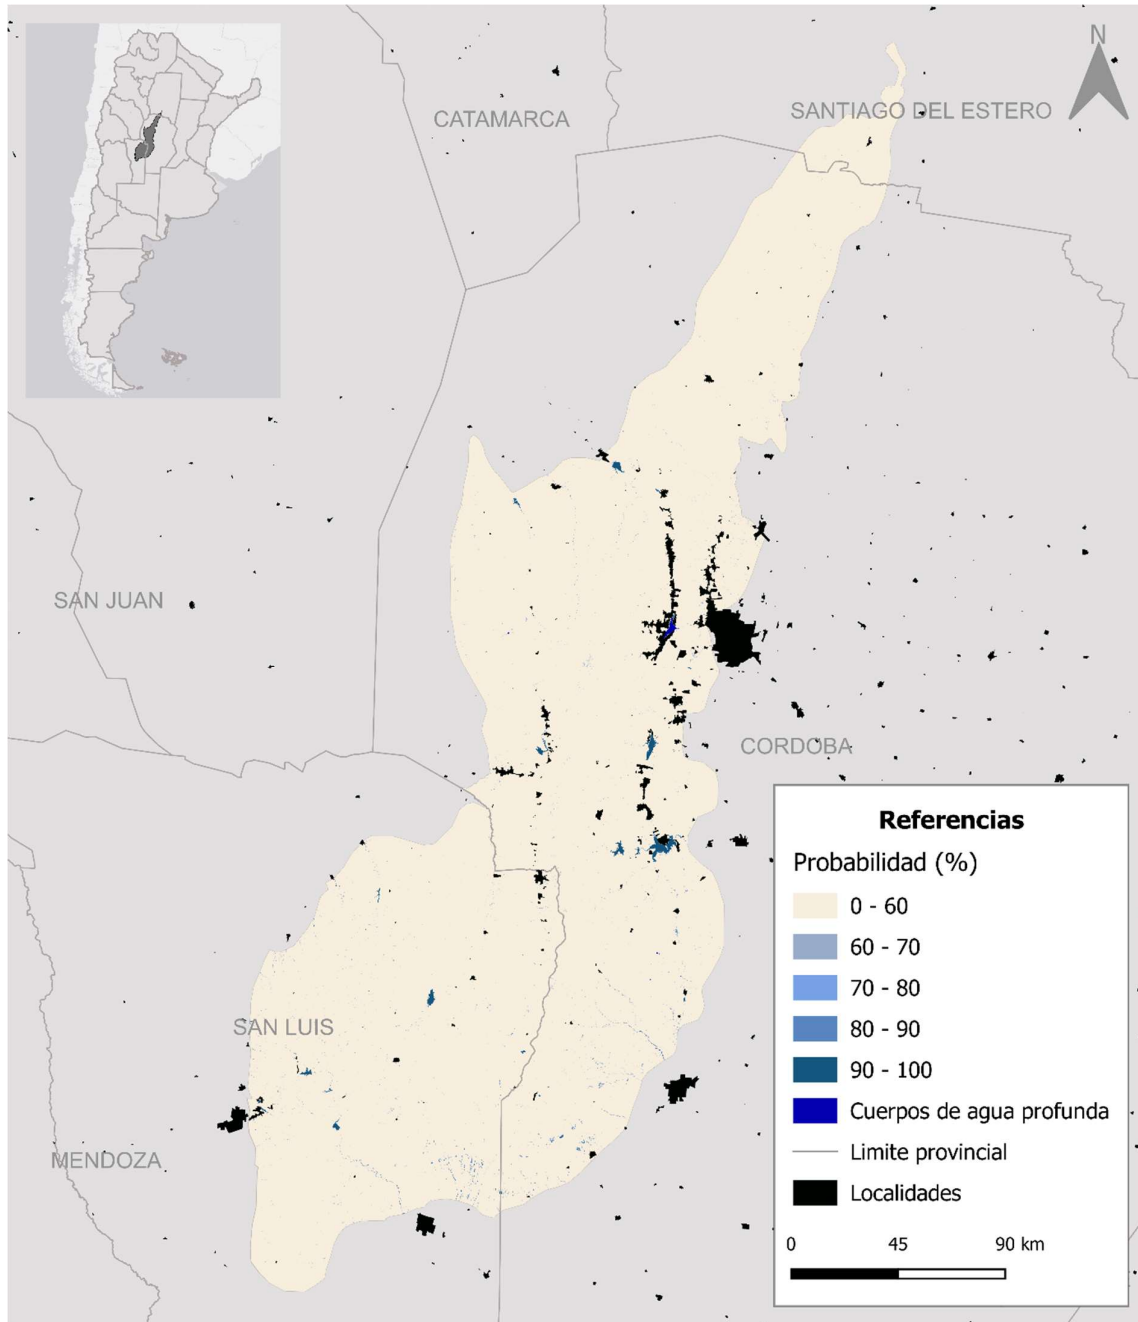




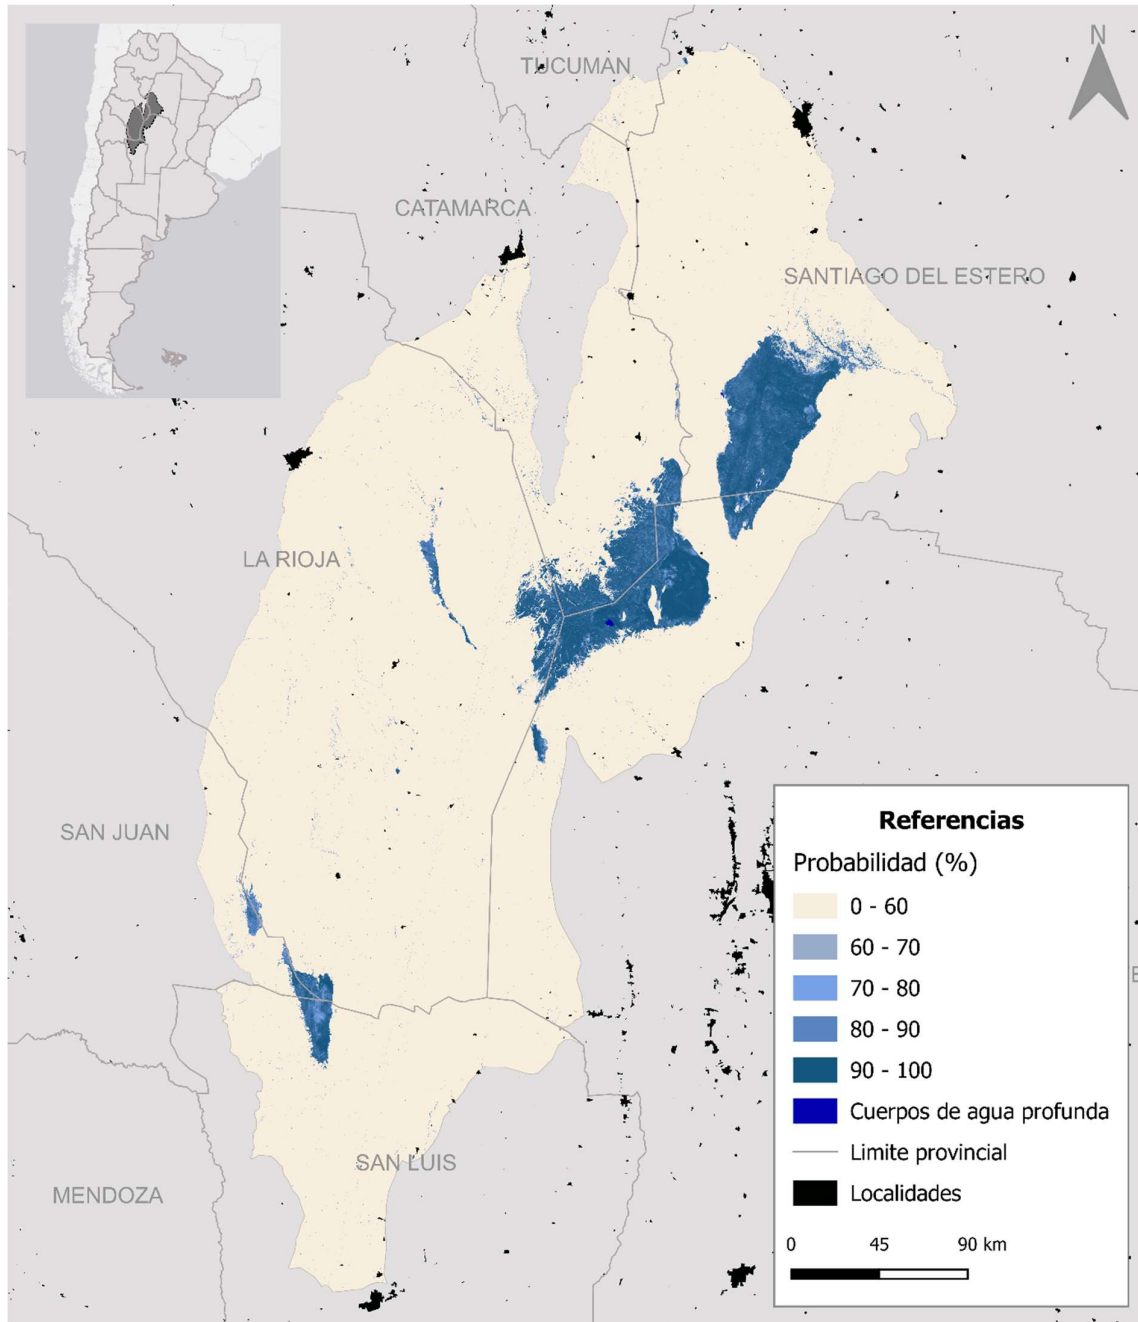
Mapa de probabilidad de humedales de la Subregión *Ríos y arroyos de los valles intermontanos*. Superficie total 1.229 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 589; 80-90% = 410; > 90% = 230 km<sup>2</sup>.



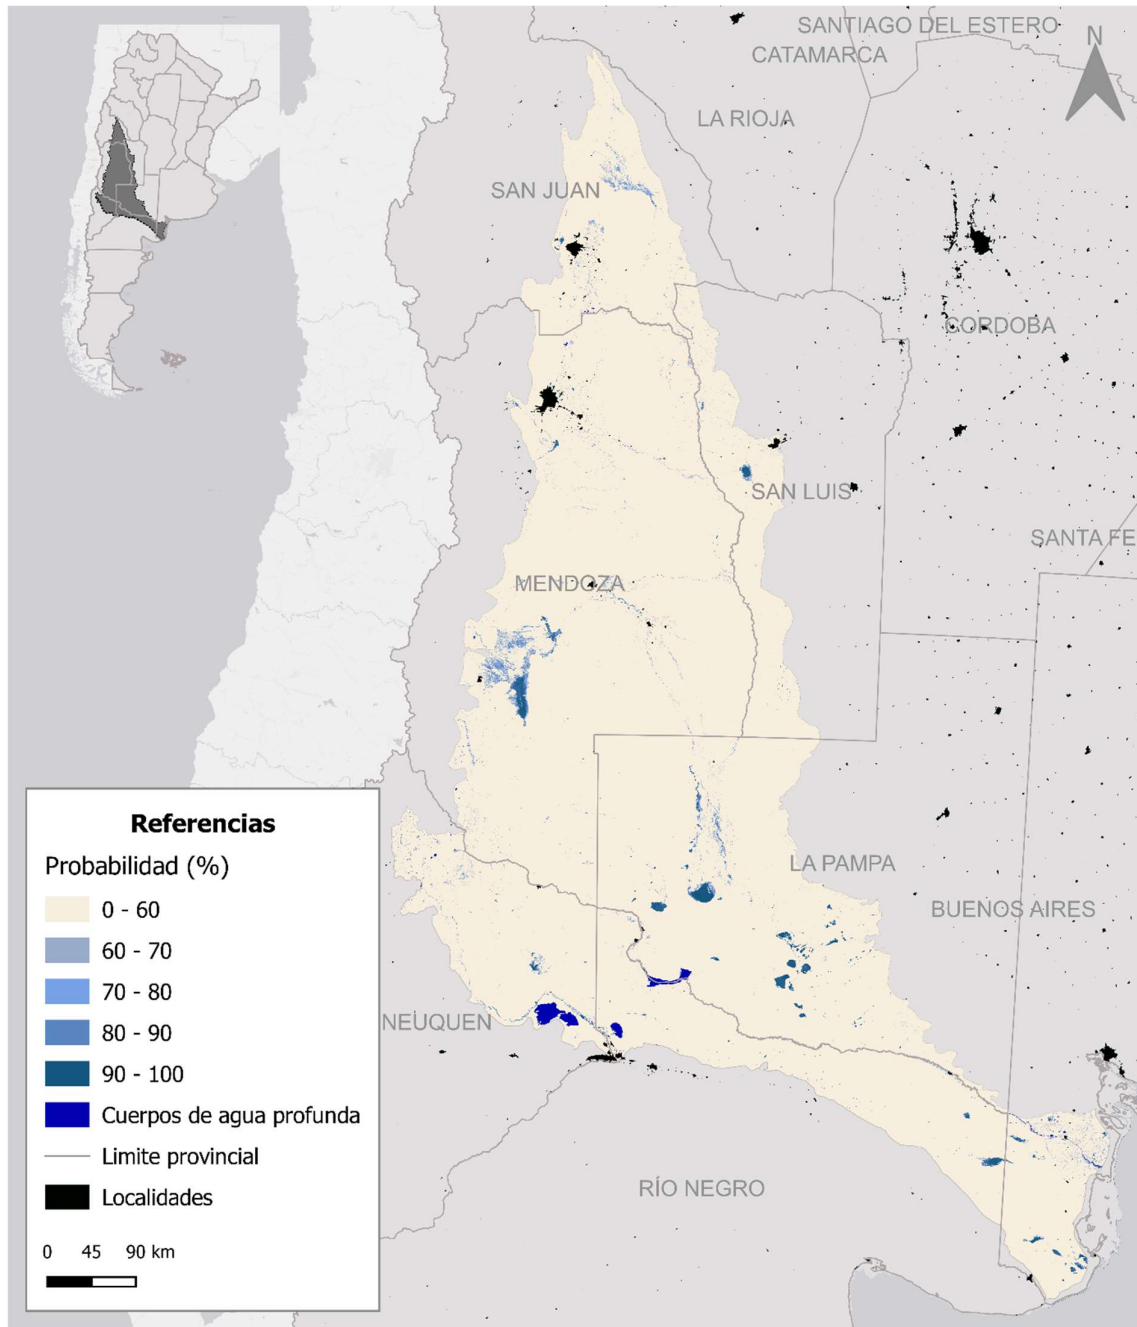
Mapa de probabilidad de humedales de la Subregión *Arroyos y mallines de las Sierras Centrales*. Superficie total 277 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 61; 80-90% = 49; > 90% = 167 km<sup>2</sup>.



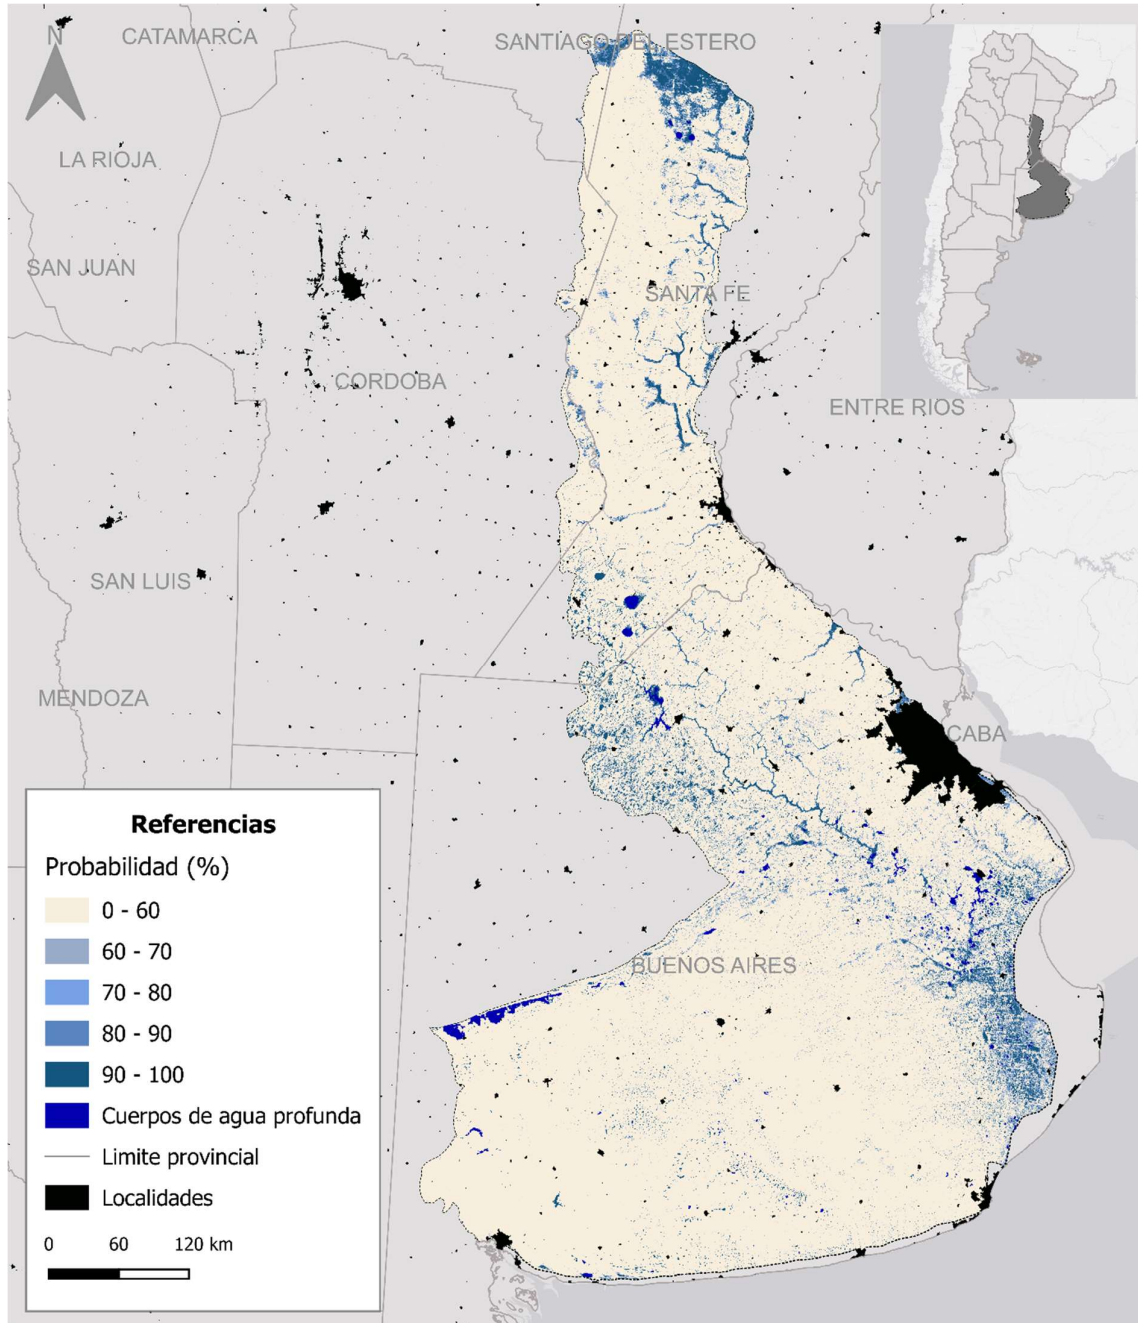
Mapa de probabilidad de humedales de la *Salinas de la depresión central*. Superficie total 9.619 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 351; 80-90% = 1.044; > 90% = 8.224 km<sup>2</sup>.



Mapa de probabilidad de humedales de la Región *Humedales del Monte Central*. Superficie total 5.497 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 1.504; 80-90% = 1.446; > 90% = 2.547 km<sup>2</sup>.

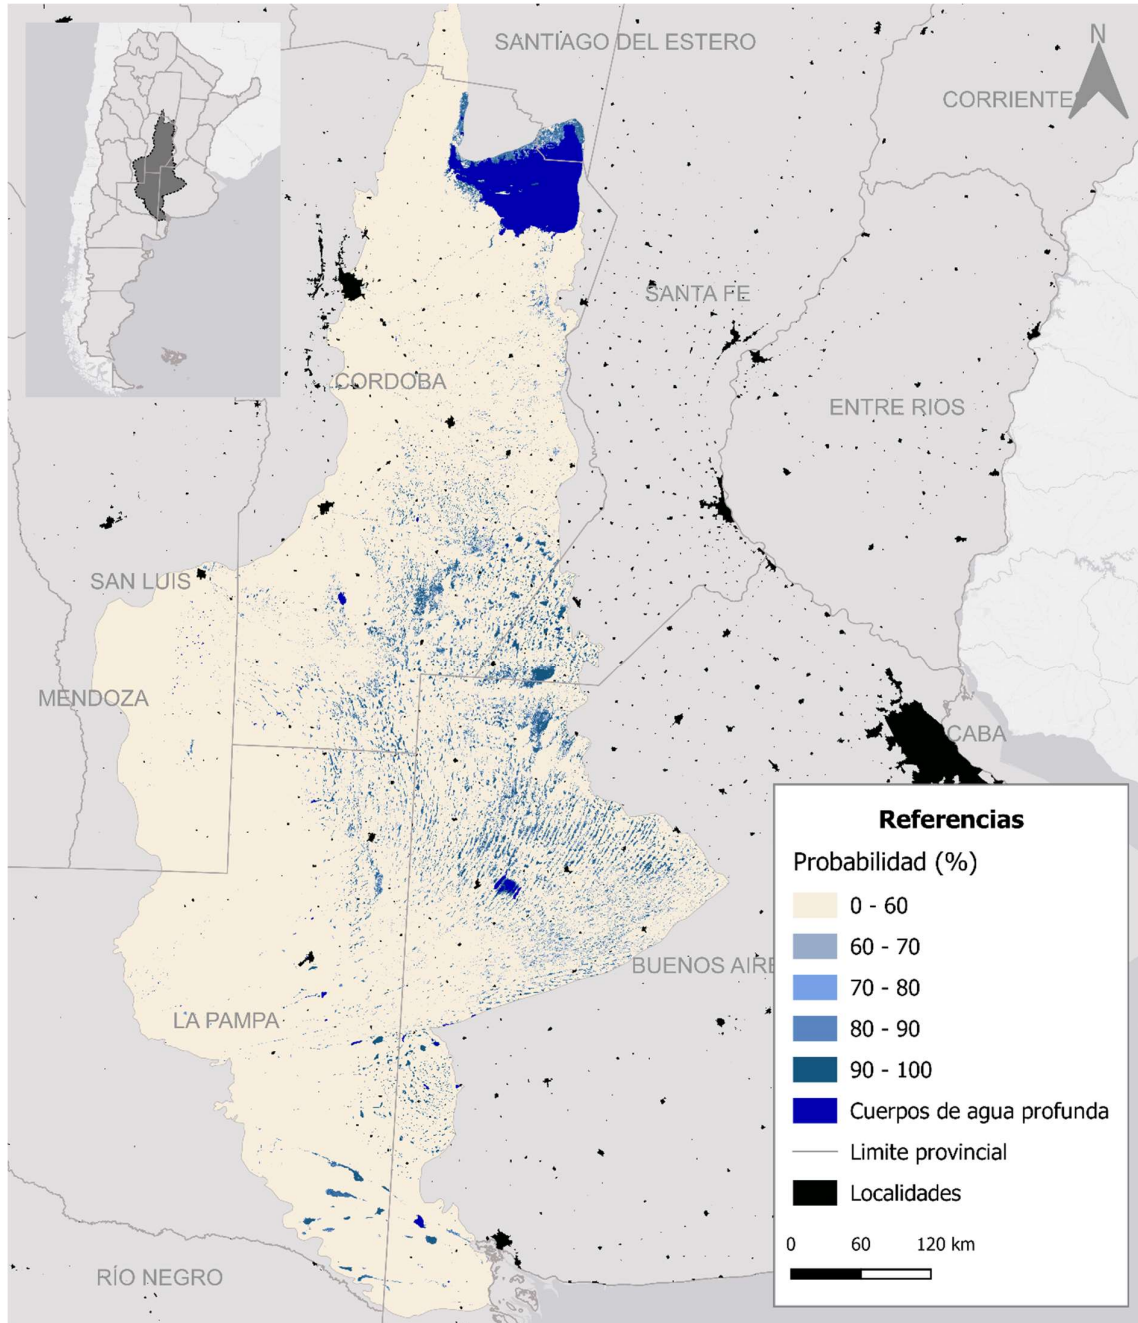


Mapa de probabilidad de humedales de la Subregión *Lagunas de la Pampa Húmeda*. Superficie total 21.521 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 3.212; 80-90% = 4.223; > 90% = 14.086 km<sup>2</sup>.

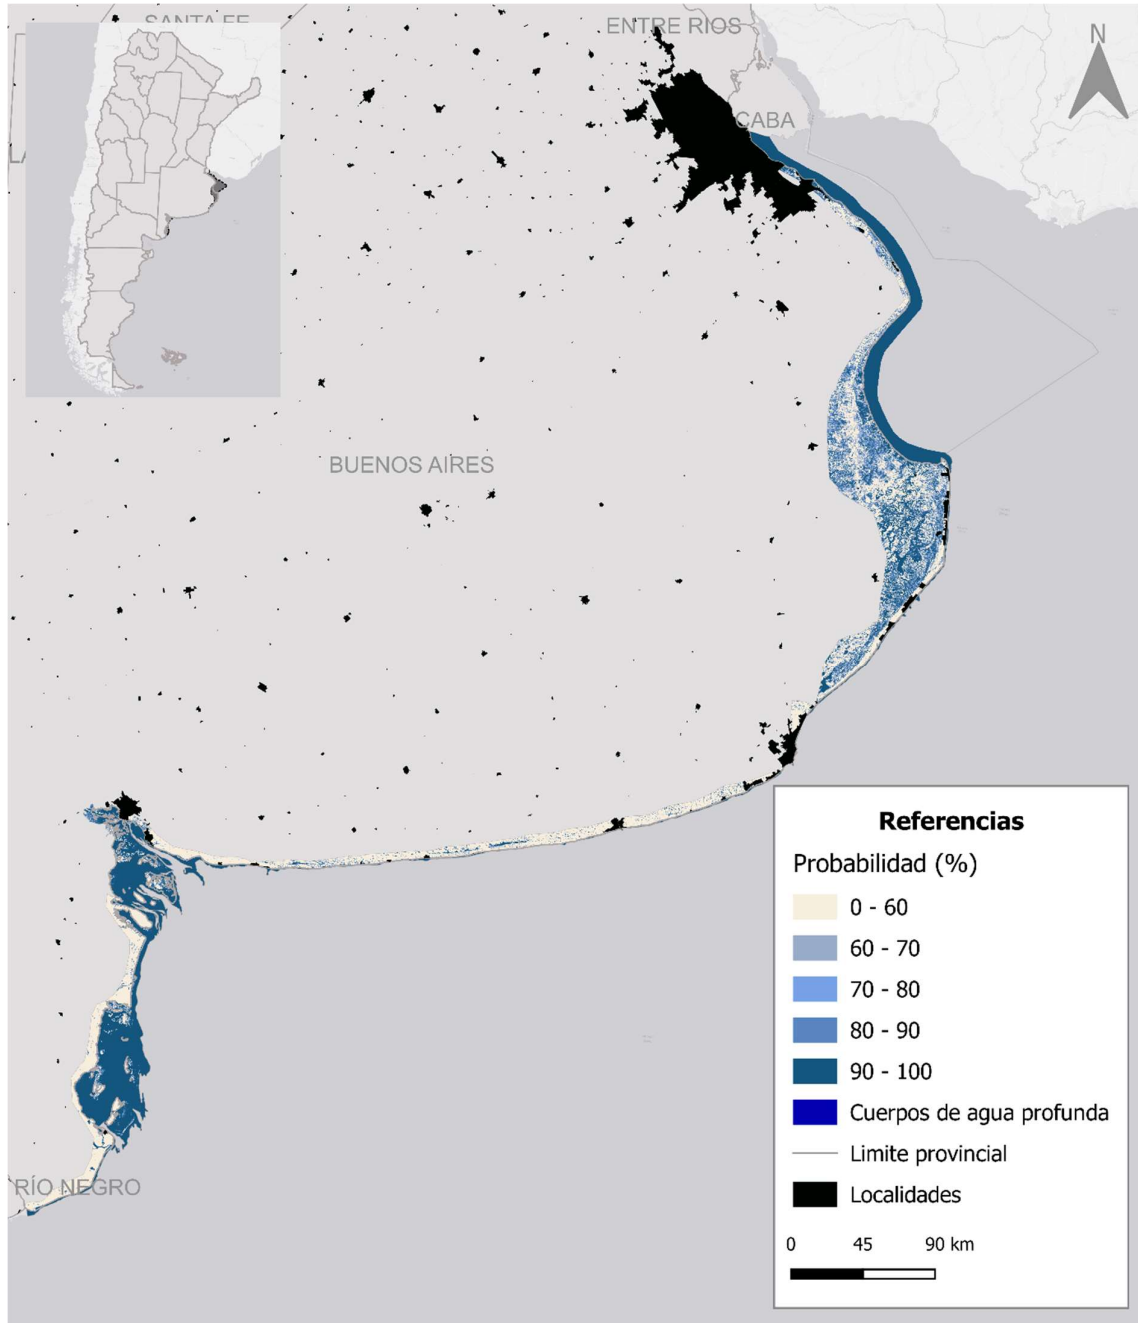




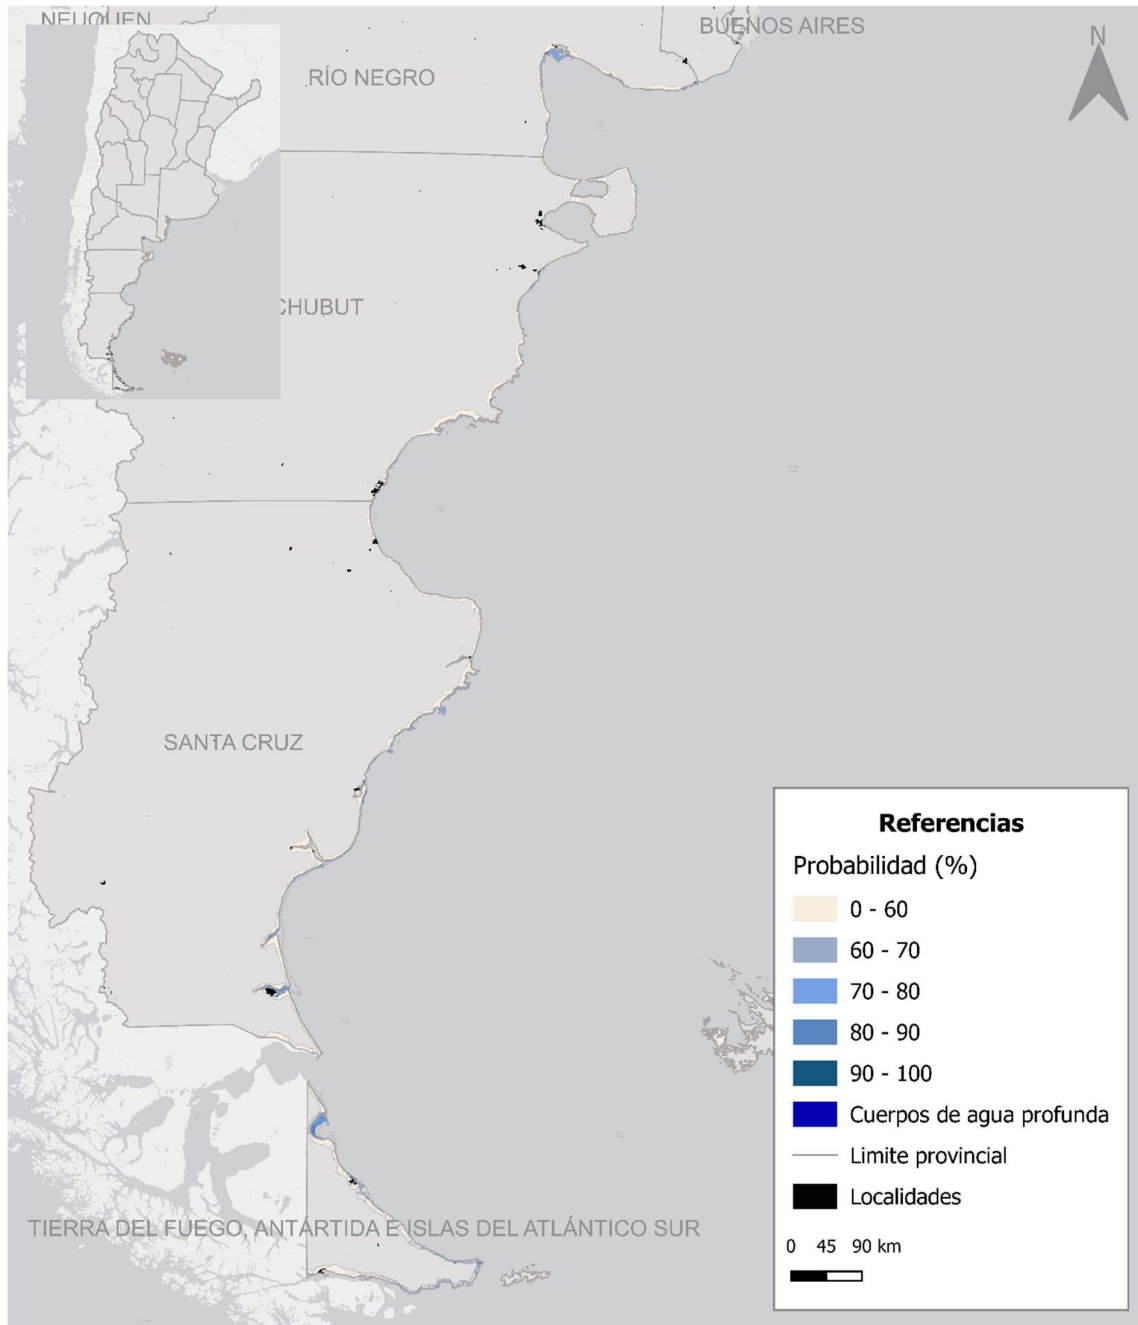
Mapa de probabilidad de humedales de la Subregión *Lagunas salobres de la pampa interior*. Superficie total 16.600 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 2.200; 80-90% = 3.947; > 90% = 10.453 km<sup>2</sup>.



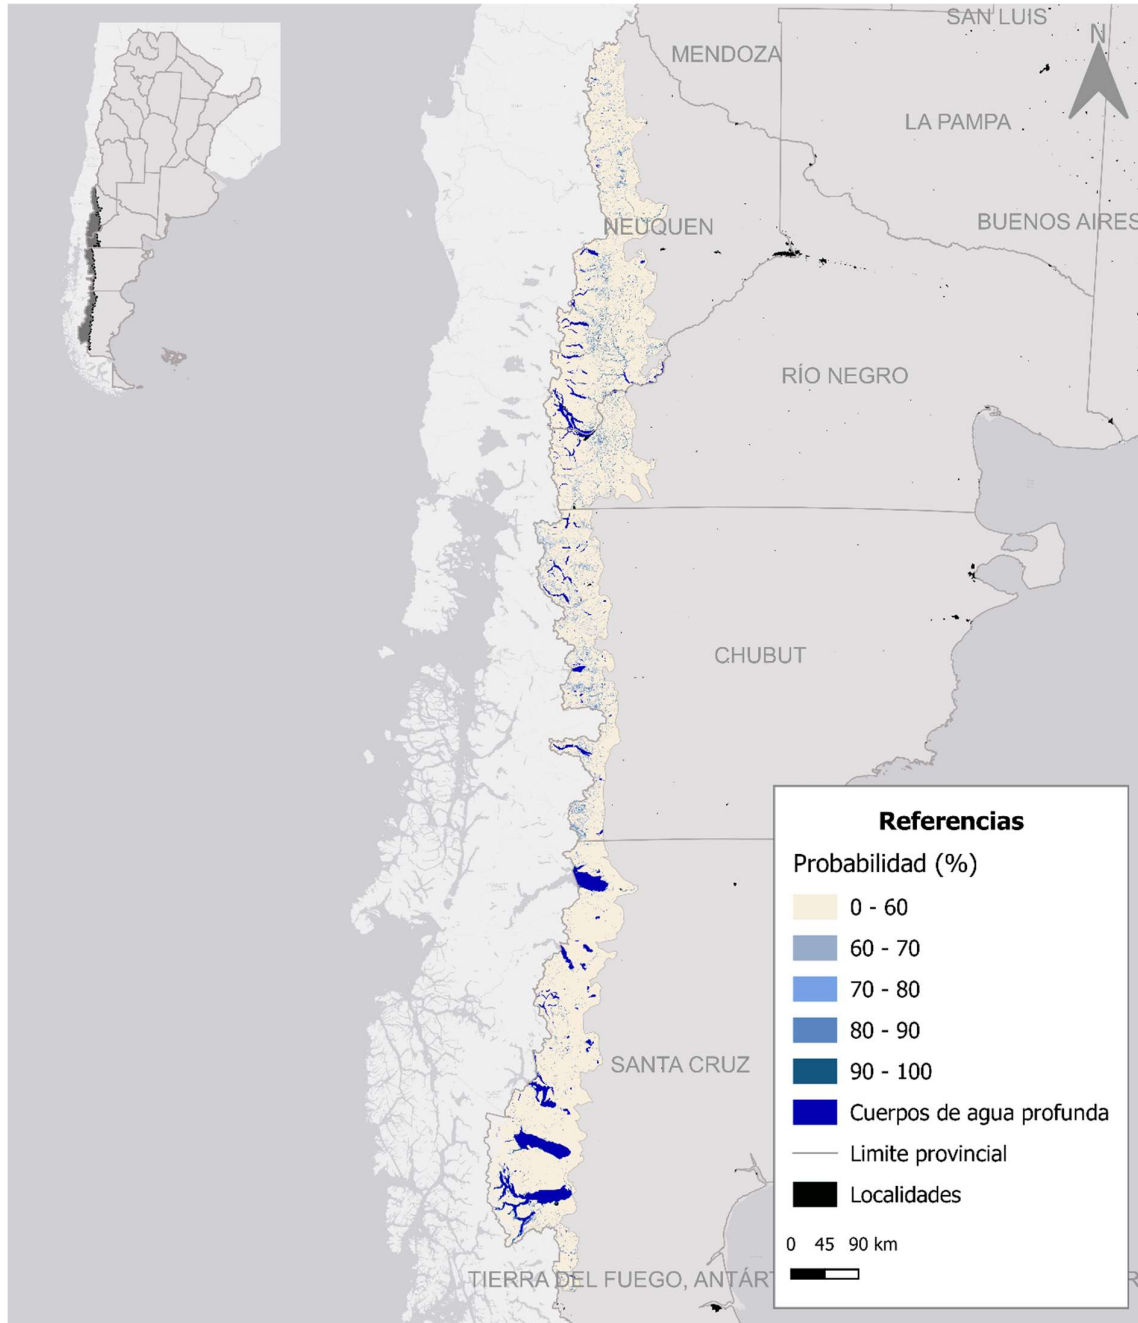
Mapa de probabilidad de humedales de la Subregión *Playas y marismas de la costa bonaerense*. Superficie total 7.667 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 657; 80-90% = 1.193; > 90% = 5.817 km<sup>2</sup>.



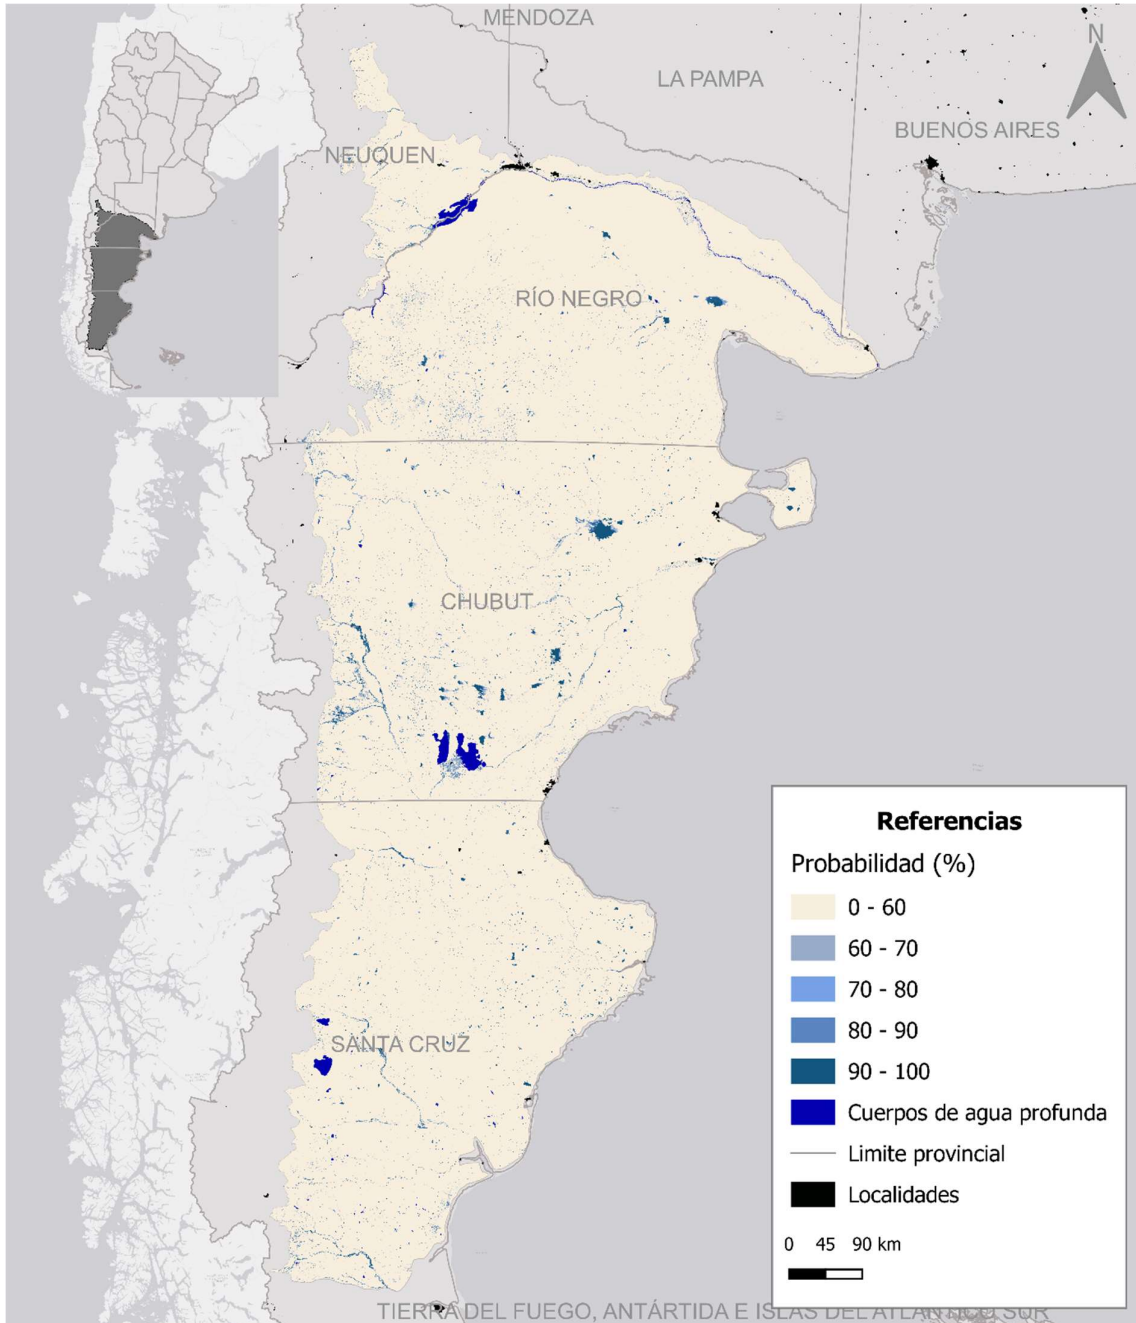
Mapa de probabilidad de humedales de la Subregión *Playas y marismas de la costa patagónica*. Superficie total 5.529 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 734; 80-90% = 1.039; > 90% = 3.756 km<sup>2</sup>.



Mapa de probabilidad de humedales de Subregión *Lagos, cursos de agua y mallines patagónicos*. Superficie total 6.110 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 1.936; 80-90% = 2.103; > 90% = 2.071 km<sup>2</sup>.

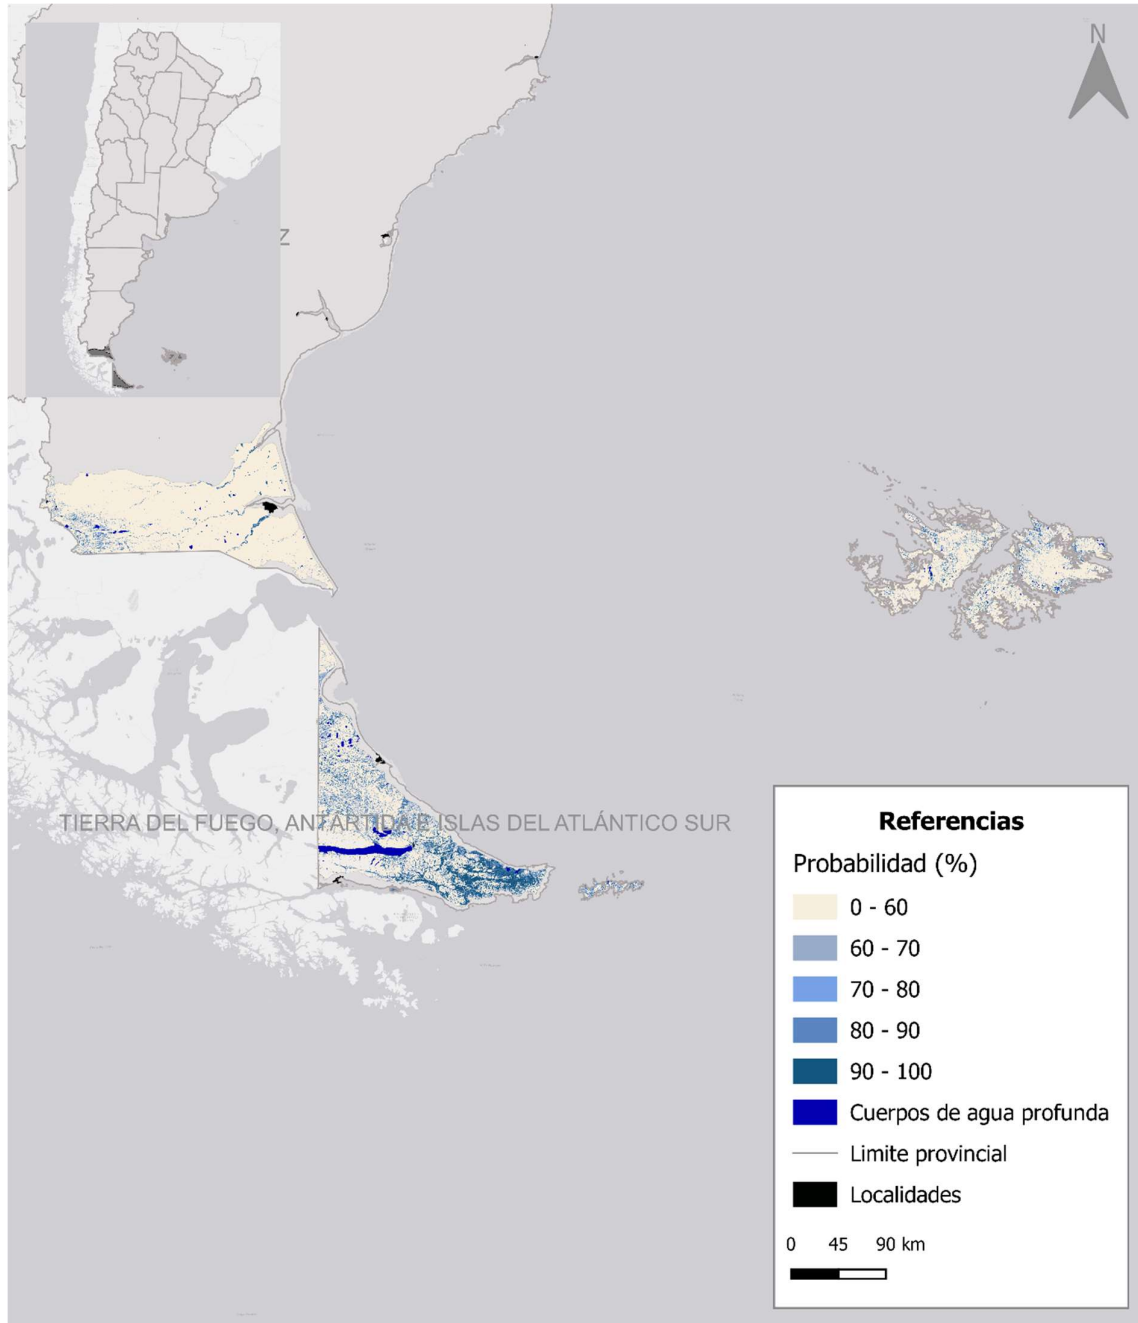


Mapa de probabilidad de humedales de la Subregión *Lagunas y vegas de la Patagonia extraandina*. Superficie total 11.167 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 1.816; 80-90% = 2.168; > 90% = 7.133 km<sup>2</sup>.





Mapa de probabilidad de humedales de la Subregión *Mallines y turberas de la Patagonia sur*. Superficie total 10.491 km<sup>2</sup>. Superficie según rangos de probabilidad: 70-80% = 1492; 80-90% = 2760; > 90% = 6239 km<sup>2</sup>.







Instituto Nacional de  
Tecnología Agropecuaria  
Argentina

