

Detección de bosques de tierras secas mediante generalización de firmas espectrales

BÁRBARA GUIDA-JOHNSON^{1,2,✉} & MARÍA A. ARANDA²

¹Instituto Argentino de Nivología, Glaciología y Ciencias Ambientales (IANIGLA), Universidad Nacional de Cuyo, Gobierno de Mendoza, CONICET. Mendoza. ²Facultad de Ciencias Exactas y Naturales, Universidad Nacional de Cuyo. Mendoza.

RESUMEN. Los bosques de tierras secas se encuentran entre los más amenazados y menos estudiados del mundo. Detectarlos y monitorearlos con imágenes satelitales de resolución media presenta limitaciones derivadas de su estructura naturalmente abierta. Por ende, se han propuesto metodologías que incorporan información de imágenes de muy alta resolución; estas metodologías están comprometidas por la baja disponibilidad de imágenes en algunas regiones. El objetivo de este trabajo es evaluar la factibilidad de implementar la generalización de firmas espectrales para apoyar la detección multitemporal de los bosques de tierras secas, tomando como caso de estudio un bosque de algarrobo en Mendoza (Argentina). Este enfoque utiliza firmas espectrales de imágenes obtenidas en fechas diferentes a las de la imagen que se clasifica. Se comparó la generalización de firmas con el enfoque tradicional; es decir, utilizando firmas únicamente de la fecha bajo análisis. Para cada una de las tres fechas estudiadas también se evaluaron 9 tipos de clasificaciones, variando 1) la adición o ausencia de un índice espectral al mosaico que se clasifica; 2) el esquema de clasificación, y 3) el clasificador. Se construyeron matrices de error y se calcularon métricas de exactitud de los mapas. La exactitud total de las clasificaciones basadas en la generalización de firmas espectrales fue igual o mayor que la de las clasificaciones realizadas con firmas de la fecha analizada. Se obtuvieron mejores resultados al implementar un esquema de clasificación simple (con dos categorías: bosque y no bosque) y utilizando Random Forest. La metodología evaluada constituye un aporte valioso para el diseño de estrategias que permitan monitorear este tipo de bosques de forma remota con eficiencia, ya que se puede implementar en fechas y regiones con una cantidad insuficiente de muestras de alta resolución para clasificar y validar mapas, o donde estos datos estén muy concentrados en el espacio.

[Palabras clave: bosque abierto, imágenes satelitales, Landsat, Random Forest, Support Vector Machine]

ABSTRACT. Detection of dryland forest through spectral signatures generalization. Dryland forests are among the most threatened and least studied forests in the world. Their detection and monitoring using medium-resolution satellite imagery present limitations derived from their naturally open structure. Therefore, methodologies incorporating information from very high-resolution images have been proposed, though these are compromised by the low availability of such imagery in some regions. This work aims to evaluate the feasibility of implementing spectral signature generalization to support multitemporal detection of dryland forests, taking a carob forest in Mendoza (Argentina) as a case study. This approach uses spectral signatures from images obtained on dates different from those classified. Signature generalization was compared with the traditional approach (i.e., using signatures only from the date under analysis). For each of the three dates studied, nine types of classifications were evaluated, varying 1) the addition or absence of a spectral index to the mosaic being classified; 2) the classification scheme; and 3) the classifier. Error matrices were constructed, and map accuracy metrics were calculated. The overall accuracy of classifications based on spectral signature generalization was equal to or greater than that of classifications performed using signatures from the analyzed date. Better results were obtained for classification types by implementing a simple classification scheme (two categories: forest and non-forest) and using Random Forest. The evaluated methodology constitutes a valuable contribution to designing strategies for efficient remote monitoring of these types of forests, particularly because it can be implemented on dates and in regions with insufficient numbers of high-resolution samples for classification and map validation, or where these data are highly spatially concentrated.

[Keywords: open woodland, satellite images, Landsat, Random Forest, Support Vector Machine]

INTRODUCCIÓN

Los bosques de tierras secas se encuentran entre los más amenazados y menos estudiados del mundo (Miles et al. 2006; FAO 2019). Las tierras secas ocupan el 47% de la superficie terrestre (Koutroulis 2019) y se caracterizan por condiciones ambientales muy particulares marcadas por la escasez, irregularidad e infrecuencia de las precipitaciones, gran amplitud térmica diaria y suelos con poca materia orgánica y agua (UNCCD 2012). En estas condiciones viven 2.6 mil millones de personas que dependen de los sistemas de bosques para satisfacer algunas de sus necesidades (Bastin et al. 2017; Koutroulis 2019). Estos bosques proveen alimentos para las personas y el ganado, energía, productos madereros y no madereros, entre otros (Sunderland et al. 2015), a algunas de las poblaciones más vulnerables del planeta (Reynolds et al. 2007). En términos globales, la deforestación amenaza esta provisión de bienes y servicios. En particular, una alta proporción de los bosques en retroceso se localizan en regiones áridas y semiáridas (FAO and UNEP 2020).

De acuerdo con las distintas estimaciones realizadas, entre 6 y 19% de las tierras secas estarían cubiertas por bosques (Hansen et al. 2013; Bastin et al. 2017). En parte, estas diferencias son producto de la consideración de diferentes definiciones de bosque propuestas a lo largo del tiempo por distintos organismos con diversos objetivos (Martínez Pastur et al. 2023). Una de las variables más relevantes que forma parte de estas definiciones es la cobertura arbórea (i.e., la proporción del suelo que se encuentra cubierta por la proyección vertical de las copas de los árboles). Cabe destacar que los bosques de tierras secas, por las condiciones ambientales en las que se encuentran, presentan de forma natural niveles de cobertura que se hallan en torno a los umbrales de algunas de dichas definiciones. Según el índice de aridez utilizado, se puede considerar que en la Argentina, entre la mitad y los dos tercios del territorio son parte de las tierras secas (ONDTyD n.d.). En estas regiones, por ejemplo, los algarrobales del Monte presentan un patrón de distribución condicionado por la disponibilidad hídrica, lo que determina que naturalmente sea muy fragmentado y heterogéneo (Villagra et al. 2004). Estos algarrobales se encuentran entre los bosques con mayores limitaciones ambientales del país, presentando un estrato arbóreo abierto dominado por *Neltuma flexuosa*

o *N. chilensis*, acompañados por *Geoffroea decorticans* (Villagra and Alvarez 2019).

En la Argentina existe un marco normativo que protege estos ecosistemas bajo la Ley Nacional N° 26.331/07 de Presupuestos Mínimos de Protección Ambiental de los Bosques Nativos. Esta legislación establece que cada jurisdicción provincial debe identificar y ordenar sus bosques nativos, produciendo un Ordenamiento Territorial de Bosque Nativo (OTBN). A fin de uniformar la aplicación de dicha legislación en todo el territorio nacional, la Resolución N° 230/12 del Consejo Federal de Medio Ambiente acordó una definición de bosque para ser utilizada en la elaboración de los OTBN provinciales. Así, son considerados como bosques nativos aquellos ambientes arbolados de 0.5 ha de ocupación continua, 3 m de altura mínima y 20% de cobertura de copas mínima (COFEMA 2012). Asimismo, la legislación establece lineamientos en relación con la consideración dentro del OTBN de bosques que hayan sido transformados por distintos disturbios o acciones antrópicas.

El ordenamiento de bosques se sustenta fuertemente en usar imágenes satelitales y técnicas de teledetección para identificar los bosques a proteger. En particular, resulta de especial relevancia el análisis multitemporal de imágenes satelitales, que provee información sobre los cambios de cobertura de la tierra. En este contexto, las imágenes de la serie Landsat ofrecen múltiples ventajas derivadas de la disponibilidad de bandas multiespectrales; en particular, las bandas en la región del infrarrojo cercano y medio del espectro electromagnético, que son muy útiles para identificar la vegetación; un tamaño de píxel (30 m) que permite detectar características a escala de paisaje (que se corresponde bien con la escala de manejo), y una escala temporal muy amplia (escenas disponibles desde inicios de los años '80), con una frecuencia de revisita que aporta gran detalle (16 días) (Young et al. 2017). Además, estas escenas están disponibles de forma libre en la plataforma Google Earth Engine, que ofrece gran capacidad de procesamiento en la nube para regiones extensas (Gorelick et al. 2017). Por lo tanto, estas herramientas presentan un alto potencial para monitorear y gestionar los bosques nativos.

Sin embargo, existe una fuente significativa de incertidumbre en las estadísticas globales de bosques de tierras secas, relacionada con las dificultades asociadas a su detección mediante

sensores remotos. Esto se debe a que cuando se usan imágenes satelitales de resolución media (como las imágenes de la serie Landsat), cada píxel suele incluir más de un tipo de cobertura del suelo, dado que se trata de sistemas de bosques abiertos (Carreiras et al. 2006). Esto llevó a diseñar metodologías que, integrando la información derivada de imágenes de muy alta y media resolución, permiten detectar más confiablemente los bosques de tierras secas (Bastin et al. 2017; Guida-Johnson et al. 2021). En especial, Guida-Johnson et al. (2021) generaron recomendaciones para detectar algarrobales en el Monte utilizando datos de cobertura de árboles, obtenidos por interpretación visual a partir de imágenes de muy alta resolución disponibles en Google Earth y Bing Maps. En ese trabajo se utilizó esa información como datos de entrenamiento para clasificar imágenes de media resolución (obtenidas por medio de los sensores de Sentinel y Landsat). Este abordaje tiene potencial para ser extrapolado a cualquier bosque de tierras secas. Sin embargo, la disponibilidad de imágenes de muy alta resolución es muy desigual a nivel mundial, con sesgos hacia determinadas regiones (Lesiv et al. 2018). Esto impone serias desventajas a la hora de intentar implementar este tipo de metodologías, especialmente cuando es necesario realizar análisis multitemporales.

Una forma de superar este obstáculo es a partir de una clasificación basada en la generalización de firmas espectrales o extensión de firmas (Pax-Lenney et al. 2001; Sexton et al. 2013). La generalización implica que un clasificador se entrena con datos de un dominio (espacial o temporal) y clasifica datos de otro dominio (Pax-Lenney et al. 2001). Si bien cualquier clasificación supervisada es técnicamente una generalización porque el clasificador se entrena a partir de muestras de entrenamiento obtenidas de unos grupos de píxeles para aplicarse a otros grupos de píxeles, en este caso, se propone utilizar muestras de entrenamiento de imágenes satelitales obtenidas en fechas diferentes a las de la imagen que se clasifica. El objetivo de este trabajo es evaluar la factibilidad de implementar la generalización de firmas espectrales para apoyar la detección multitemporal de los bosques de tierras secas, tomando como caso de estudio un bosque de algarrobo de Mendoza (Argentina). Para esto, se analizó la disponibilidad de datos de muy alta resolución espacial en el área de estudio y se evaluaron distintos tipos de clasificaciones

basadas en la generalización de firmas para generar mapas de bosque. Luego, estos mapas se compararon con otros obtenidos mediante el abordaje tradicional; es decir, utilizando firmas espectrales correspondientes únicamente a la fecha bajo análisis.

MATERIALES Y MÉTODOS

Área de estudio

El área de estudio de este trabajo se localiza en el sureste de la provincia de Mendoza (Argentina), entre las latitudes 34.33° S y 36.10° S y las longitudes 66.38° O y 68.20° O. Abarca el departamento de General Alvear y parte del departamento de San Rafael en Mendoza, parte de la provincia de San Luis y parte de La Pampa, ocupando ~3 millones de hectáreas (Figura 1). Se ubica en la región biogeográfica del Monte; específicamente, en una zona desértica de clima subtropical a templado. El desierto del Monte constituye la ecorregión más árida de la Argentina (Abraham et al. 2009). El área de estudio se caracteriza por una precipitación media anual de 329 mm y una temperatura media anual de 15.4 °C. La vegetación es xerófila y presenta un estrato superior dominado por *Neltuma flexuosa* (algarrobo dulce) y *Geoffroea decorticans* (chañar); incluye un estrato arbustivo representado por *Larrea cuneifolia* y *L. divaricata* (jarilla), *Atriplex lampa* (zampa), *A. undulata* (zampa crespá), *Neltuma alpataco* (alpataco) y *Condalia microphylla* (piquillín); y un estrato herbáceo con *Aristida mendocina* (flechilla), *Leptochloa crinita* (pasto de hoja) y *Panicum urvilleanum* (tupe), entre otras (Cesca 2011). De acuerdo con las estadísticas del Sistema Nacional de Monitoreo de Bosques de la República Argentina (snmb.ambiente.gob.ar/develop/), la mayor cantidad de incendios de bosques de la provincia de Mendoza se concentra en los departamentos de San Rafael y, en mayor medida, en General Alvear.

Obtención de firmas espectrales

La técnica de generalización de firmas espectrales se basa en clasificar una imagen satelital a partir de un conjunto de muestras de entrenamiento obtenidas para fechas diferentes. Siguiendo el abordaje propuesto por Guida-Johnson et al. (2021), la disponibilidad de firmas espectrales queda limitada solo por la disponibilidad de imágenes de muy alta resolución que permitan asociar de forma inequívoca cada píxel de Landsat con un valor

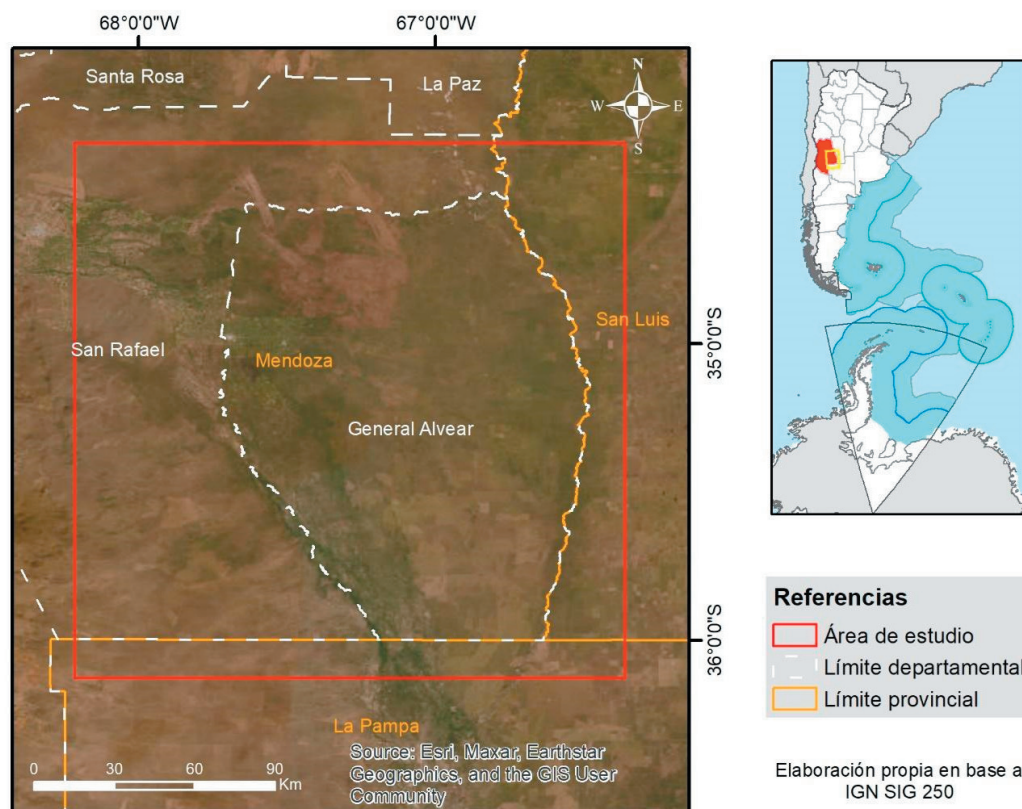


Figura 1. Localización del área de estudio.

Figure 1. Location of the study area.

confiable de cobertura de árboles. Para esto, se utilizó el programa Collect Earth, que permite cuantificar mediante interpretación visual la cobertura de copas a partir de imágenes disponibles en Google Earth.

En primer lugar, se determinó la disponibilidad de imágenes de muy alta resolución en el área de estudio. A partir de un mosaico de imágenes Landsat elaborado para toda el área de estudio, se obtuvieron los centroides de cada píxel, de los cuales se seleccionaron 5000 puntos al azar distribuidos de forma uniforme. Revisando el catálogo de imágenes históricas de Google Earth, se determinó que para 2026 puntos no había imágenes disponibles. Los restantes 2974 puntos fueron asociados con imágenes de muy alta resolución distribuidas a lo largo de 12 años: 5 puntos se asociaron a una escena de 2002; 62 puntos, a 2007; 131 puntos, a 2010; 10 puntos, a 2012; 363 puntos, a 2013; 298 puntos, a 2014; 111 puntos, a 2016; 23 puntos, a 2017; 15 puntos, a 2018; 897 puntos, a 2019; 764 puntos, a 2020 y 295 puntos, a 2021 (Figura 2). En términos generales, cabe destacar que se observa que los puntos correspondientes a

cada año se concentran en ciertas regiones del área de estudio. Para cada uno de esos 2974 puntos, se determinó el valor de cobertura de copas del píxel realizando una cuantificación por interpretación visual mediante la grilla de Collect Earth (Bey et al. 2016).

Todos los procesamientos que se describen a continuación se realizaron en la plataforma Google Earth Engine (Gorelick et al. 2017). Para extraer las firmas espectrales de los 2974 puntos, se construyeron mosaicos para cada año a partir de imágenes corregidas atmosféricamente a reflectancia en superficie. Para los años 2002 a 2013, se utilizaron imágenes del catálogo Landsat 7, Level 2, Collection 2, Tier 1, mientras que para los años 2014 a 2021 se utilizaron imágenes del catálogo Landsat 8, Level 2, Collection 2, Tier 1. Se usó una máscara para excluir aquellos píxeles con nubes y sombras y se aplicaron los factores de escala de Landsat. Los mosaicos se compusieron seleccionando escenas obtenidas durante los períodos de mayor expresión vegetativa del bosque, considerando que dichos períodos sean lo suficientemente amplios como para contar con escenas libres

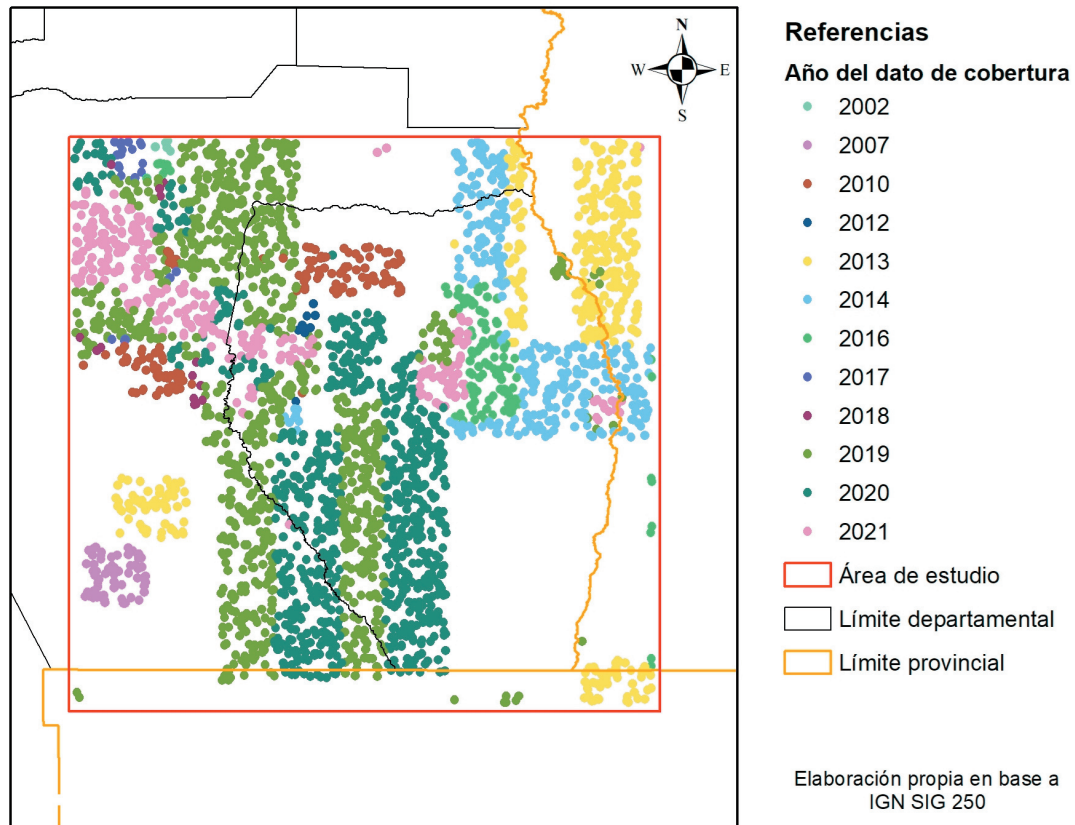


Figura 2. Distribución de los datos de cobertura de árboles obtenidos a partir de imágenes alta resolución espacial.
Figure 2. Distribution of tree cover data obtained from high spatial resolution images.

del error de línea de escaneo del sensor de Landsat 7. Por lo tanto, se utilizaron escenas obtenidas entre el 1 de septiembre del año previo y el 30 de abril del año bajo análisis, componiendo cada mosaico a partir del valor de la mediana para cada píxel.

Clasificación de imágenes

Si se desea realizar un análisis multitemporal para monitorear el estado del bosque o detectar cambios, es suficiente construir mapas de bosque compuestos por dos clases de cobertura: bosque y no-bosque. Cuando la superficie del área de estudio es mayor a 400000 ha, se recomienda utilizar entre 75 y 100 muestras por clase de cobertura para validar los mapas (Congalton 1991). Por lo tanto, en nuestra área de estudio, los datos de alta resolución espacial disponibles serían suficientes para clasificar y validar sin recurrir a la generalización de firmas espectrales en 2013, 2014, 2019, 2020 y 2021. Es decir, solo en cinco años del período 2002-2021. De esos años, se seleccionaron las siguientes

fechas de análisis: 2013, 2019 y 2021. Así se puede comparar la generalización de firmas espectrales con el abordaje tradicional (i.e., sin generalizar) para ambos satélites (Landsat 7 y 8) y utilizando distinta cantidad de datos de alta resolución.

Los mosaicos que se clasifican son los mismos que se compusieron para extraer las firmas espectrales para los años 2013 (Landsat 7), 2019 y 2020 (Landsat 8). En todos los casos, los datos de alta resolución correspondientes a la fecha bajo análisis fueron divididos al azar entre datos de entrenamiento y datos de validación, procurando obtener alrededor de 150 puntos de validación (considerando que se busca identificar dos clases de cobertura). Solo en los casos en los que se puso a prueba la generalización de firmas espectrales se incluyeron también los datos de cobertura de árboles correspondientes al dominio temporal completo (2002-2021) como datos de entrenamiento. Para cada fecha, se pusieron a prueba 9 tipos de clasificaciones basadas en 1) la adición o no de un índice espectral

al mosaico que se clasifica; 2) el esquema de clasificación (i.e., cómo se utilizan los datos de cobertura de árboles), y 3) el clasificador.

En relación con (1), se probó no incluir ningún índice, incorporar al mosaico una capa con el cálculo del NDVI (índice de vegetación de diferencia normalizada), ya que es uno de los índices de vegetación más utilizados o incorporar una capa con el cálculo del SATVI (índice de vegetación total ajustado al suelo). Este último demostró tener una buena correlación con la cobertura boscosa en la región del Monte y es sensible tanto a la vegetación verde como a la senescente (Goirán et al. 2012). Los índices se calculan de esta forma:

$$\text{NDVI} = (\rho_{\text{NIR}} - \rho_{\text{Red}}) / (\rho_{\text{NIR}} + \rho_{\text{Red}})$$

Ecuación 1

$$\text{SATVI} = (\rho_{\text{SWIR}} - \rho_{\text{Red}}) / (\rho_{\text{SWIR}} + \rho_{\text{Red}} + L) (1 + L) - \rho_{\text{SWIR}2} / 2$$

Ecuación 2

donde ρ_{NIR} es la reflectancia en la región del infrarrojo cercano, ρ_{SWIR} y $\rho_{\text{SWIR}2}$ son las reflectancias en el infrarrojo de onda corta, ρ_{Red} es la reflectancia en el rojo y L es un factor de ajuste al suelo, para el cual se utilizó un valor de 0.5.

En cuanto a (2), se puso a prueba un esquema de clasificación simple considerando a cada punto de entrenamiento como no bosque si la cobertura de copas de árboles se encontraba entre 0 y 19% o bosque si la cobertura de copas estaba entre 20 y 100%, y aplicando un clasificador. Alternativamente, se utilizó el rango completo de cobertura de copas y se realizó una regresión mediante el algoritmo Random Forest para obtener un mapa con valores continuos de cobertura, los cuales fueron reclasificados como no bosque (cobertura entre 0 y 19%) y bosque (cobertura entre 20 y 100%).

En relación con (3), para los casos en los que se utilizó el esquema de clasificación simple, se pusieron a prueba dos clasificadores que suelen obtener los mejores niveles de desempeño: el algoritmo Random Forest (RF), ajustado a 100 árboles; o Support Vector Machine (SVM), para el cual se utilizó la función de base radial (RBF), se seleccionó 0.5 y 100 como gamma y costo, respectivamente. Los parámetros fueron ajustados poniendo a prueba distintos valores y evaluando visualmente los resultados (Aduña et al. 2022).

Los puntos de validación seleccionados al azar se utilizaron para construir matrices de error y calcular las siguientes métricas cuantitativas: exactitud total, exactitud del productor y exactitud del usuario. La exactitud total representa la proporción de píxeles correctamente clasificados. La exactitud del productor indica la probabilidad de que un dato de referencia esté correctamente clasificado en el mapa, mientras que la exactitud del usuario representa la probabilidad de que un punto en el mapa represente esa clase en el terreno (Congalton 1991).

RESULTADOS

En términos generales, la exactitud total de las clasificaciones basadas en la generalización de firmas espectrales fue igual o mayor que la de las clasificaciones realizadas únicamente a partir de las firmas de la fecha bajo análisis (Tabla 1 y Tabla 2). Lo mismo ocurre cuando se analizan los valores de exactitud del productor y del usuario, ya que, considerando todos los tipos de clasificaciones, el 61% de las métricas fueron iguales o mayores para los casos basados en la generalización de firmas. Para estas últimas, los valores de exactitud total se encontraron en el rango entre 0.69 y 0.84; la exactitud del productor del no-bosque, entre 0.43 y 0.95; la exactitud del productor del bosque, entre 0.41 y 0.96; la exactitud del usuario del no-bosque, entre 0.54 y 0.87, y la exactitud del usuario del bosque, entre 0.67 y 0.93. Por su parte, para las clasificaciones realizadas siguiendo el abordaje tradicional (i.e., sin generalización), los valores de exactitud total se encontraron en el rango entre 0.71 y 0.85; la exactitud del productor del no-bosque, entre 0.36 y 0.98; la exactitud del productor del bosque, entre 0.37 y 0.98; la exactitud del usuario del no-bosque, entre 0.53 y 0.89, y la exactitud del usuario del bosque, entre 0.69 y 0.92. Entre estas últimas, en aquellos casos en los que la exactitud del usuario disminuyó significativamente, se observó a simple vista una sobreestimación de la superficie clasificada como bosque. Cabe destacar que, en dichos casos, a pesar de dicha sobreestimación, la exactitud total obtuvo valores altos.

En relación con las clasificaciones basadas en la generalización de firmas espectrales, para los años 2013 y 2019, cuando no se adicionó ningún índice espectral al mosaico que se clasifica, se alcanzó un valor de exactitud total igual que cuando se adicionó NDVI o

Tabla 1. Métricas de exactitud para las clasificaciones basadas en la generalización de firmas espectrales. Los tonos de gris creciente señalan valores de los coeficientes en estos rangos [0.70-0.80), [0.80-0.90) y [0.90-1.00].**Table 1.** Accuracy metrics for classifications based on spectral signature generalization. Increasing shades of gray indicate coefficient values in these ranges [0.70-0.80), [0.80-0.90) and [0.90-1.00].

Año	Suma índice	Esquema clasificación	Clasificador	Exactitud total	Exactitud productor		Exactitud usuario	
					No bosque	Bosque	No bosque	Bosque
2013	No	Simple	RF	0.74	0.81	0.65	0.73	0.74
			SVM	0.76	0.79	0.73	0.78	0.74
			Regresión	0.73	0.93	0.44	0.70	0.82
	NDVI	Simple	RF	0.74	0.86	0.56	0.75	0.72
			SVM	0.76	0.78	0.73	0.82	0.68
			Regresión	0.71	0.95	0.41	0.67	0.87
	SATVI	Simple	RF	0.69	0.77	0.58	0.70	0.67
			SVM	0.74	0.71	0.78	0.81	0.68
			Regresión	0.77	0.92	0.50	0.76	0.79
2019	No	Simple	RF	0.84	0.58	0.96	0.87	0.83
			SVM	0.82	0.51	0.96	0.85	0.81
			Regresión	0.73	0.67	0.75	0.54	0.84
	NDVI	Simple	RF	0.80	0.48	0.93	0.72	0.81
			SVM	0.75	0.43	0.88	0.59	0.79
			Regresión	0.73	0.69	0.75	0.56	0.84
	SATVI	Simple	RF	0.83	0.66	0.90	0.71	0.87
			SVM	0.81	0.49	0.93	0.71	0.83
			Regresión	0.75	0.73	0.76	0.62	0.84
2021	No	Simple	RF	0.73	0.74	0.72	0.55	0.86
			SVM	0.77	0.62	0.85	0.64	0.83
			Regresión	0.71	0.84	0.64	0.54	0.89
	NDVI	Simple	RF	0.77	0.83	0.72	0.64	0.88
			SVM	0.72	0.64	0.78	0.62	0.78
			Regresión	0.78	0.85	0.75	0.58	0.93
	SATVI	Simple	RF	0.79	0.84	0.76	0.66	0.90
			SVM	0.77	0.61	0.86	0.71	0.80
			Regresión	0.75	0.83	0.72	0.60	0.89

Tabla 2. Métricas de exactitud para las clasificaciones que utilizan firmas espectrales únicamente de la fecha analizada. Los tonos de gris creciente señalan valores de los coeficientes en estos rangos [0.70-0.80), [0.80-0.90) y [0.90-1.00].**Table 2.** Accuracy metrics for classifications using spectral signatures only from the analyzed date. Increasing shades of gray indicate coefficient values in these ranges [0.70-0.80), [0.80-0.90) and [0.90-1.00].

Año	Suma índice	Esquema clasificación	Clasificador	Exactitud total	Exactitud productor		Exactitud usuario	
					No bosque	Bosque	No bosque	Bosque
2013	No	Simple	RF	0.73	0.88	0.55	0.70	0.80
			SVM	0.72	0.96	0.42	0.67	0.91
			Regresión	0.71	0.93	0.41	0.69	0.81
	NDVI	Simple	RF	0.77	0.86	0.63	0.78	0.74
			SVM	0.74	0.84	0.58	0.75	0.69
			Regresión	0.71	0.98	0.37	0.66	0.92
	SATVI	Simple	RF	0.73	0.83	0.62	0.73	0.74
			SVM	0.71	0.87	0.51	0.69	0.75
			Regresión	0.76	0.91	0.50	0.75	0.77
2019	No	Simple	RF	0.79	0.47	0.94	0.78	0.79
			SVM	0.78	0.36	0.98	0.89	0.77
			Regresión	0.72	0.67	0.74	0.53	0.84
	NDVI	Simple	RF	0.80	0.59	0.89	0.68	0.84
			SVM	0.75	0.41	0.89	0.60	0.79
			Regresión	0.75	0.69	0.78	0.59	0.85
	SATVI	Simple	RF	0.85	0.73	0.89	0.71	0.90
			SVM	0.79	0.41	0.94	0.71	0.81
			Regresión	0.75	0.76	0.75	0.62	0.85
2021	No	Simple	RF	0.73	0.83	0.68	0.54	0.90
			SVM	0.78	0.68	0.83	0.64	0.85
			Regresión	0.77	0.78	0.77	0.63	0.88
	NDVI	Simple	RF	0.73	0.69	0.76	0.62	0.81
			SVM	0.75	0.58	0.85	0.70	0.78
			Regresión	0.79	0.73	0.81	0.61	0.88
	SATVI	Simple	RF	0.73	0.79	0.71	0.59	0.86
			SVM	0.73	0.54	0.84	0.65	0.77
			Regresión	0.77	0.67	0.82	0.65	0.83

SATVI, respectivamente. En cambio, en 2021 se alcanzaron mayores valores incorporando SATVI. Analizando el esquema de clasificación, se obtuvieron los mejores valores de exactitud total con el esquema simple. En cuanto al clasificador, con Random Forest se obtuvieron los mayores niveles de exactitud total.

En cuanto a las clasificaciones que utilizan el abordaje tradicional (i.e., aquellas en las que solo se utilizan las firmas espectrales cuya fecha coincide con la del mosaico que se clasifica), los resultados obtenidos para la adición de los índices fueron más variables. En el año 2013 se obtuvieron mayores valores de exactitud total incluyendo el NDVI; en 2019 se obtuvieron mejores valores con SATVI, y en 2021 fue similar incluir NDVI o no incorporar ningún índice. En relación con el esquema de clasificación, para estas clasificaciones volvieron a obtenerse los mejores valores de exactitud total con el esquema simple. Entre estas últimas, nuevamente Random Forest obtuvo el mejor desempeño.

DISCUSIÓN

La generalización de firmas espectrales demostró robustez para apoyar la detección multitemporal de los bosques de tierras secas. Al igual que en otro caso reportado para bosques de coníferas, las clasificaciones basadas en la generalización en el tiempo y el espacio obtienen precisiones comparables con los métodos usualmente utilizados (Woodcock et al. 2001). En este trabajo se obtuvieron valores de exactitud de los mapas iguales —e incluso mayores— que cuando se utilizan solo las firmas espectrales de las fechas bajo análisis. Por lo tanto, puede considerarse que se obtendrían buenos valores de exactitud si se implementara la generalización de firmas para fechas en las que no se disponga de datos de alta resolución suficientes para clasificar y validar. Esto es relevante considerando las limitaciones derivadas del hecho de que en determinadas regiones la disponibilidad de imágenes de muy alta resolución es baja (Lesiv et al. 2018). Por ejemplo, en el área de estudio, de la serie temporal de 20 años disponible (2002-2021) solo se cuenta con datos suficientes para 5 años. Asimismo, cabe destacar que aun cuando los datos de alta resolución sean suficientes en cantidad, se pueden localizar concentrados en determinadas regiones. Por lo tanto, al trabajar en regiones más extensas, las clasificaciones no presentan buena calidad y se cometen errores que no son detectados

por las métricas de exactitud, en tanto que los datos que se utilizan están sesgados. Por lo tanto, la generalización de firmas espectrales permite superar estos obstáculos, lo que es especialmente relevante en regiones como los bosques de tierras secas. Estos principios pueden extrapolarse a cualquier ecosistema cuya detección por interpretación visual en imágenes de media resolución sea limitada.

En cuanto a los tipos de clasificaciones puestos a prueba, no se encontraron patrones claros en relación con la mejora de la exactitud derivada de la inclusión de índices espectrales al mosaico que se clasifica como en trabajos previos (Guida-Johnson et al. 2021). Considerando las ventajas vinculadas a la automatización de los procedimientos que permite la plataforma de Google Earth Engine, es posible que el uso de índices se deba considerar y ajustar a la medida de cada área de estudio. En este trabajo sí se detectó un mejor desempeño derivado de la utilización de un esquema de clasificación simple (i.e., compuesto por dos clases de cobertura: bosque y no-bosque) y del algoritmo Random Forest para clasificar.

En términos generales, este trabajo vuelve a destacar las ventajas que ofrece la serie Landsat a la hora de abordar estudios multitemporales (Young et al. 2017). A pesar de su gran resolución temporal, la resolución espacial de estas imágenes impone restricciones para la toma de muestras de entrenamiento por interpretación visual en los bosques abiertos de las regiones áridas y semiáridas debido a la multiplicidad de coberturas dentro de cada píxel (Carreiras et al. 2006). En estos bosques, la respuesta radiométrica de un píxel es generada por más de un tipo de cobertura, por lo cual existe un nivel inherente de error en los datos colectados asociado a la subjetividad del observador y la dificultad de interpretar y diferenciar correctamente colores y texturas (Strahler et al. 2006). A pesar de reconocerse las dificultades asociadas a las limitaciones en las técnicas de teledetección (Sexton et al. 2016; Fagan 2020), no existen acuerdos generales en relación con el mejor método para identificar y monitorear los bosques de tierras secas. En este sentido, las propuestas metodológicas que combinan información de imágenes de muy alta y media resolución son alternativas viables (Bastin et al. 2017; Guida-Johnson et al. 2021). Si bien este abordaje se basa en la falta de variación en la relación cobertura-firma espectral, esta puede verse comprometida

por diversos factores como la fenología o las condiciones atmosféricas (Sexton et al. 2013). En este sentido, la disponibilidad de imágenes corregidas a reflectancia en superficie que ofrece la plataforma de Google Earth Engine representa una gran ventaja para implementar este tipo de abordaje de una forma simplificada.

Existe una falta de consenso en relación con la distribución global de los bosques de tierras secas, lo que resulta preocupante dado que las diferencias en las estimaciones rondan los millones de hectáreas (Bastin et al. 2017). Cuando se comparan bases de datos globales con mapas elaborados a escala regional, se detectan grandes diferencias. Por ejemplo, la capa de cobertura de la tierra elaborada por el Componente Global del Servicio Terrestre de Copernicus (European Commission 2015) no detecta parches con cobertura de bosque en el área de estudio de este trabajo. De manera similar, el producto de cambio forestal global de la Universidad de Maryland (Hansen et al. 2013) —cuyo mapa base utiliza el año 2000 como referencia— tampoco identifica cobertura forestal en el área de estudio. Si contrastamos nuestros resultados con los del Global Forest Watch para el año 2010, observamos una situación intermedia: sí se detecta superficie de bosque, aunque en una magnitud considerablemente menor (Global Forest Watch n.d.). En este sentido, es muy relevante proponer estrategias y metodologías que permitan detectar los bosques de tierras secas a escala regional o de paisaje. De hecho, nuestros resultados presentan gran coincidencia con los mapas de uso y cobertura del suelo elaborados por el Proyecto MapBiomias Argentina. La clasificación del año 2013, que no incluye ningún índice espectral, se basa en el esquema de clasificación simple y utiliza el clasificador Support Vector Machine detecta el 73% de la cobertura de vegetación natural leñosa cerrada

del mapa de MapBiomias para el sector del área de estudio (Proyecto MapBiomias Argentina 2024a). Por otro lado, la clasificación del año 2019 que incluye SATVI se basa en el esquema simple y utiliza Random Forest detecta el 82% (Proyecto MapBiomias Argentina 2024b).

En el marco de la Ley Nacional N° 26.331/07, la Resolución N° 230/12 de COFEMA establece que las áreas en las que se perdieron bosques nativos como consecuencia de disturbios antrópicos son de interés, ya que pueden incorporarse a los OTBN provinciales en sus actualizaciones cuando adquieran las características definidas para el bosque (COFEMA 2012). De esta forma, el monitoreo de estos ambientes es fundamental para asegurar su protección y los análisis multitemporales con imágenes satelitales facilitan esta tarea. Cabe destacar que el análisis de imágenes satelitales ópticas tiene la limitación de no poder detectar la altura de los árboles, que es un atributo que forma parte de las distintas definiciones de bosque (COFEMA 2012; Hansen et al. 2013; Martínez Pastur et al. 2023). Entendiendo que estos análisis deben ser complementados con validaciones a campo a los fines de generar herramientas útiles para gestionar estos ecosistemas, la detección remota de los bosques nativos resulta fundamental para sistematizar el análisis periódico a través de grandes extensiones. Estos bosques, además de constituir componentes importantes en el hábitat de otras especies (i.e., nido para aves, refugio para roedores) y tener efectos sobre las condiciones ambientales, tales como el clima local o la fertilidad del suelo (Villagra 2000), ofrecen bienes y servicios ecosistémicos claves para el bienestar de los pobladores locales (Villagra and Alvarez 2019). En este sentido, la metodología evaluada en este trabajo constituye un aporte valioso al diseño de estrategias que permitan monitorearlos de forma remota con eficiencia.

REFERENCIAS

- Abraham, E. M., H. F. del Valle, F. Roig, L. Torres, J. O. Ares, F. Coronato, and R. Godagnone. 2009. Overview of the geography of the Monte Desert Biome (Argentina). *Journal of Arid Environments* 73:144-153. <https://doi.org/10.1016/j.jaridenv.2008.09.028>.
- Adugna, T., W. Xu, and J. Fan. 2022. Comparison of Random Forest and Support Vector Machine classifiers for regional land cover mapping using coarse resolution FY-3C images. *Remote Sensing* 14:574. <https://doi.org/10.3390/rs14030574>.
- Bastin, J.-F., N. Berrahmouni, A. Grainger, D. Maniatis, D. Mollicone, R. Moore, C. Patriarca, et al. 2017. The extent of forest in dryland biomes. *Science* 356:635-638. <https://doi.org/10.1126/science.aam6527>.
- Bey, A., A. S. P. Díaz, D. Maniatis, G. Marchi, D. Mollicone, S. Ricci, J. F. Bastin, R. Moore, S. Federici, et al. 2016. Collect Earth: Land use and land cover assessment through augmented visual interpretation. *Remote Sensing* 8:1-24. <https://doi.org/10.3390/rs8100807>.
- Carreiras, J. M. B., J. M. C. Pereira, and J. S. Pereira. 2006. Estimation of tree canopy cover in evergreen oak woodlands

- using remote sensing. *Forest Ecology and Management* 223:45-53. <https://doi.org/10.1016/j.foreco.2005.10.056>.
- Cesca, E. M. 2011. Influencia del fuego en la estructura y dinámica de los algarrobales del sudeste de Mendoza. Tesis de doctorado, Universidad Nacional de Córdoba.
- COFEMA. 2012. Resolución 230/12 Aprobación de documento elaborado por técnicos y autoridades provinciales de bosques nativos. URL: tinyurl.com/2s3f49ez.
- Congalton, R. G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment* 37:35-46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).
- European Commission. 2015. Land Cover 2015-2019 (raster 100 m), global, annual - version 3. URL: tinyurl.com/3sywk866.
- Fagan, M. E. 2020. A lesson unlearned? Underestimating tree cover in drylands biases global restoration maps. *Global Change Biology* 26:4679-4690. <https://doi.org/10.1111/gcb.15187>.
- FAO. 2019. Trees, forests and land use in drylands: the first global assessment. Full report. Rome.
- FAO, and UNEP. 2020. The state of the world's forests 2020. Forests, biodiversity and people. Page The State of the World's Forests 2020. FAO and UNEP, Rome.
- Global Forest Watch. n.d. Forest Watcher. URL: tinyurl.com/4eb8zk46.
- Goirán, S. B., J. N. Aranibar, and M. L. Gómez. 2012. Heterogeneous spatial distribution of traditional livestock settlements and their effects on vegetation cover in arid groundwater coupled ecosystems in the Monte Desert (Argentina). *Journal of Arid Environments* 87:188-197. <https://doi.org/10.1016/j.jaridenv.2012.07.011>.
- Gorelick, N., M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202:18-27. <https://doi.org/10.1016/j.rse.2017.06.031>.
- Guida-Johnson, B., P. E. Villagra, L. M. Alvarez, F. Rojas, and J. A. Alvarez. 2021. Finding woodlands in drylands: Bases for the monitoring of xeric open forests in a cloud computing platform. *Remote Sensing Applications: Society and Environment* 22:100528. <https://doi.org/10.1016/j.rsase.2021.100528>.
- Hansen, M. C. C., P. V Potapov, R. Moore, M. Hancher, S. A. a Turubanova, A. Tyukavina, D. Thau, et al. 2013. High-resolution global maps of 21st-century forest cover change. *Science* 342:850-854. <https://doi.org/10.1126/science.1244693>.
- Koutroulis, A. G. 2019. Dryland changes under different levels of global warming. *Science of the Total Environment* 655:482-511. <https://doi.org/10.1016/j.scitotenv.2018.11.215>.
- Lesiv, M., L. See, J. C. L. Bayas, T. Sturm, D. Schepaschenko, M. Karner, I. Moorthy, I. McCallum, and S. Fritz. 2018. Characterizing the spatial and temporal availability of very high resolution satellite imagery in Google Earth and Microsoft Bing Maps as a source of reference data. *Land* 7. <https://doi.org/10.3390/land7040118>.
- Martínez Pastur, G., M. M. Amoroso, G. Baldi, M. D. Barrera, A. D. Brown, L. M. Chauchard, L. Galetto, et al. 2023. ¿Qué es un bosque nativo en la Argentina? Marco conceptual para una correcta definición de acuerdo con las políticas institucionales nacionales y el conocimiento científico disponible. *Ecología Austral* 33:152-169. <https://doi.org/10.25260/EA.23.33.1.0.2040>.
- Miles, L., A. C. Newton, R. S. DeFries, C. Ravilious, I. May, S. Blyth, V. Kapos, and J. E. Gordon. 2006. A global overview of the conservation status of tropical dry forests. *Journal of Biogeography* 33:491-505. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>.
- ONDTyD. n.d. Índice de Aridez (según UNEP, en porcentaje de la superficie nacional).
- Pax-Lenney, M., C. E. Woodcock, and S. A. Macomber. 2001. Forest mapping with a generalized classifier and Landsat TM data. *Remote Sensing of Environment* 77:241-250. [https://doi.org/10.1016/S0034-4257\(01\)00208-5](https://doi.org/10.1016/S0034-4257(01)00208-5).
- Proyecto MapBiomás Argentina. 2024a. Colección 1. Mapa anual de cobertura y uso del suelo en Argentina correspondiente al año 2013. URL: tinyurl.com/57x2c23t.
- Proyecto MapBiomás Argentina. 2024b. Colección 1. Mapa anual de cobertura y uso del suelo en Argentina correspondiente al año 2019. URL: tinyurl.com/3dmfwxz9.
- Reynolds, J. F., D. Mark, S. Smith, E. F. Lambin, B. L. T. II, M. Mortimore, S. P. J. Batterbury, T. E. Downing, et al. 2007. Global desertification: Building a science for dryland development. *Science* 316:847-851. <https://doi.org/10.1126/science.1131634>.
- Sexton, J. O., P. Noojipady, X. P. Song, M. Feng, D. X. Song, D. H. Kim, A. Anand, C. Huang, S. Channan, S. L. Pimm, and J. R. Townshend. 2016. Conservation policy and the measurement of forests. *Nature Climate Change* 6:192-196. <https://doi.org/10.1038/nclimate2816>.
- Sexton, J. O., D. L. Urban, M. J. Donohue, and C. Song. 2013. Long-term land cover dynamics by multi-temporal classification across the Landsat-5 record. *Remote Sensing of Environment* 128:246-258. <https://doi.org/10.1016/j.rse.2012.10.010>.
- Strahler, A. H., L. Boschetti, G. M. Foody, M. A. Friedl, M. C. Hansen, M. Herold, P. Mayaux, J. T. Morissette, S. V. Stehman, and C. E. Woodcock. 2006. Global land cover validation: Recommendations for evaluation and accuracy assessment of global land cover maps. *Ispra*.
- Sunderland, T., D. Apgaua, C. Baldauf, R. Blackie, C. Colfer, A. B. Cunningham, K. Dexter, H. Djoudi, D. Gautier, et al. 2015. Global dry forests: A prologue. *International Forestry Review* 17:1-9. <https://doi.org/10.1505/146554815815834813>.
- UNCCD. 2012. Desertification: a visual synthesis. URL: tinyurl.com/tt36n5rm.
- Villagra, P. E. 2000. Aspectos ecológicos de los algarrobales argentinos. *Muldequina* 9:35-51.

- Villagra, P. E., and J. A. Alvarez. 2019. Determinantes ambientales y desafíos para el ordenamiento forestal sustentable en los algarrobales del Monte, Argentina. *Ecología Austral* 29:146-155. <https://doi.org/10.25260/EA.19.29.1.0.752>.
- Villagra, P. E., M. A. Cony, N. G. Mantován, B. E. Rossi, M. M. González Loyarte, R. Villalba, and L. Marone. 2004. Ecología y manejo de los algarrobales de la Provincia Fitogeográfica del Monte. *En* J. F. Goya, J. L. Frangi and M. F. Arturi (eds.). *Ecología y manejo de los bosques de Argentina*. Investigación en bosques nativos de Argentina. Editorial de la Universidad Nacional de La Plata (EDULP).
- Woodcock, C. E., S. A. Macomber, M. Pax-Lenney, and W. B. Cohen. 2001. Monitoring large areas for forest change using Landsat: Generalization across space, time and Landsat sensors. *Remote Sensing of the Environment* 78:194-203. [https://doi.org/10.1016/S0034-4257\(01\)00259-0](https://doi.org/10.1016/S0034-4257(01)00259-0).
- Young, N. E., R. S. Anderson, S. M. Chignell, A. G. Vorster, R. Lawrence, and P. H. Evangelista. 2017. A survival guide to Landsat preprocessing. *Ecology* 98:920-932. <https://doi.org/10.1002/ecy.1730>.