

Maestria en Produccion Ganadera de Zonas Áridas- Facultad de Ciencias Agrarias-
UNCuyo

**Identificación de áreas homogéneas en zonas áridas mediante imágenes satelitales
procesadas con Machine Learning.**

Maestrando:

Ing. Agr. Geronimo Adrián Iglesias

Director: Ing.Agr. MsC Fabio Marcos Tacchini

Codirector: Ing.Agr.Mgtr. Marcos Montoya

Agradecimientos - Dedicatoria:

A mis abuelos paternos, Geromo y Antonia, fundadores de una pasión

A mis abuelos maternos, Ines y Salvador

Santiago, Nicolas, Gabriel y por su intermedio a toda la familia Pietrelli por su apoyo
incondicional

Mi esposa Mariana y nuestros hijos: Leticia, Francisco y Amalia

A mis padres, Ines y Julio

Fabio Tacchini

Silvia Van den Bosch

Dante Crisman

Facultad de Ciencias Agrarias- UNCuyo

CREA Pehuenche

ÍNDICE

ÍNDICE.....	1
1. INTRODUCCIÓN.....	2
1.a. Áreas Homogéneas.....	2
1.b. Uso de imágenes satelitales para la determinación de áreas homogéneas.....	4
1.c. Determinación de áreas homogéneas aplicada a la evaluación forrajera de sistemas pastoriles extensivos.....	6
2. OBJETIVOS E HIPÓTESIS.....	7
2.a. OBJETIVO GENERAL.....	7
3. Hipótesis:.....	8
4. Material y Método:.....	8
4.a. Sitio Experimental.....	8
4.b. Procesamiento de datos satelitales para la determinación de áreas homogéneas	12
4.b.1. Software utilizado.....	12
4.b.2. Elección del sensor.....	13
4.b.3. Selección de áreas de entrenamiento.....	16
4.b.4. Métodos de clasificación.....	17
4.b.5. Procedimientos aplicados: Maximum Likelihood y Random Forests.....	18
4.c. Análisis de series temporales de imágenes satelitales para determinar el régimen de incendios.....	22
5.Resultados y discusión.....	23
5.a. Clasificación de áreas homogéneas.....	23
5.a.1. Random Forest vs Maximum Likelihood: Invierno y Verano.....	23
5.b. Determinación de zonas afectadas por eventos de fuego.....	28
5.c. Efecto del fuego sobre las áreas homogéneas.....	31
5.d. Receptividad ganadera - Impacto del Olivillo.....	34
5.e. Recomendaciones prácticas que surgen del análisis de la afectación producida por el fuego y de las áreas homogéneas determinadas.....	35
6. Conclusiones.....	36
Consideraciones finales:.....	39
7.BIBLIOGRAFÍA.....	41

Identificación de áreas homogéneas en zonas áridas mediante imágenes satelitales procesadas con Machine Learning.

1. INTRODUCCIÓN

1.a. Áreas Homogéneas

Cada especie vegetal posee exigencias particulares en lo que se refiere a temperatura, humedad, luz, duración del día, etc., los factores climáticos son principales en la repartición de las plantas sobre la tierra. También son factores muy importantes la fisiografía, el tipo de suelo y otros factores antrópicos (Cabrera, 1971). El concepto de áreas homogéneas o fragmentos, en el estudio de la vegetación o ecología del paisaje se refiere a zonas donde la distribución de las especies es uniforme, con características similares en términos de composición florística, estructura y condiciones ambientales (Mateucci y Colma, 1982). Turner y Gardner, 2015, definen como fragmentos a aquellas áreas que difieren de su entorno en su naturaleza o apariencia. Para reducir la complejidad del estudio de la estructura del paisaje se calculan métricas del paisaje (Matteucci, 1998), que son el resultado de la aplicación de métodos cuantitativos en estudios de ecología del paisaje (Vila-Subirós et al., 2006). A través de su aplicación e interpretación, se analiza la estructura del paisaje sobre mapas categóricos pudiendo comparar entre distintas configuraciones paisajísticas, la misma área en distintos momentos temporales o la definición de escenarios futuros (Peña-Cortés *et al*, 2006; Vila-Subirós *et al*, 2006).

La homogeneidad puede evaluarse a diferentes escalas (Baghdadi *et al*;2018) y puede depender del patrón espacial de las especies, la composición florística y las características del hábitat. La identificación de áreas homogéneas o fragmentos es crucial para diseñar un muestreo eficiente y obtener datos representativos de la comunidad vegetal, facilitando la comparación y el análisis de los datos. Además, en estudios de regionalización ecológica, la vegetación se utiliza para delimitar unidades ecológicas, lo cual es útil para la planificación y gestión del ambiente, así como para la evaluación de la tierra con fines agropecuarios, forestales, urbanísticos o conservacionistas (Comiso, 2022; Torre Azzaroni, 2022;Perez *et al*, 2020). Es destacable, que a pesar de los esfuerzos, no todos los paisajes serán susceptibles

de ser definidos (Turner y Gardner, 2015). En el estudio de la vegetación, a nivel de comunidades, es imposible operativamente medir a todos los individuos, por lo que dicha medición la realizamos a través de muestreos y mediante ellos poder obtener estimaciones de ciertos parámetros de interés de las comunidades vegetales.

(Mateucci y Colma 1982; Easdale *et al.* 2019)

Las formaciones vegetales o comunidades vegetales constituyen componentes muy importantes, desde diversos puntos de vista (ecologista, paisajístico, productivista, etc.), para la caracterización de una determinada área, región o establecimiento por lo que su descripción resulta de mucho interés. En su descripción debemos considerar dos aspectos centrales que son el florístico y el fisonómico. La descripción florística hace referencia a las especies presentes en determinado lugar y a partir de éstas caracterizar la vegetación desde el arreglo particular de dichas especies (lista de especies del lugar). Por otro lado, la fisonómica está determinada por la proporción en que cada forma de vida (ej.: árboles, arbustos, hierbas, musgos, etc.) contribuye a conformar el paisaje, es decir, es una descripción desde el punto de vista estructural a través del ordenamiento espacial de los estratos. Por otro lado, las formaciones vegetales, son resultantes de múltiples combinaciones posibles de factores ambientales (suelo, agua, incidencia de fuego, entre otros) (Herrera-Calvo y Díaz-Varela, 2013). Para caracterizar florística y fisonómicamente necesitamos estimar ciertos atributos de la vegetación los cuales pueden ser cualitativos o cuantitativos. Es importante tener en cuenta que el uso de unos u otros presenta a su vez, ventajas y desventajas. Así por ejemplo los cualitativos son muy eficientes en términos de tiempo de muestreo y costos, son muy descriptivos y sin inferencia estadística. Por otro lado, obtener atributos cuantitativos implica mayor tiempo de muestreo y sus costos son mayores, pero otorgan información más relevante. Otro aspecto importante que también debemos tener en cuenta al momento de evaluar la vegetación, se relaciona con la objetividad y subjetividad en nuestras observaciones sobre los parámetros, que está dado simplemente por el sesgo personal de lo que vemos. Así, por ejemplo, en un muestreo subjetivo, el lugar donde se realizan las evaluaciones es elegido conscientemente como un “lugar representativo” de la comunidad vegetal, mientras que, en un muestreo objetivo, el lugar es seleccionado bajo criterios metodológicos preestablecidos, por ejemplo un muestreo aleatorio o sistemático. (Mateucci y Colma 1982).

La identificación de áreas homogéneas, es de relevancia en contexto de la ganadería de zonas áridas, con el fin de cuantificar las superficies de cada unidad ecológica, asociando productividad forrajera a cada una para estimar con mayor precisión la receptividad de un establecimiento (Blanco *et al*, 2020). Asociado a la determinación de superficie, pueden aplicarse procedimientos de ajuste de producción forrajera utilizando procedimientos de regresión entre la PPNA (Productividad Primaria Neta Aérea) e índices de verde (NDVI), discriminando fracciones leñosas y herbáceas (Blanco *et al*, 2016) y a su vez aplicando ajustes por otros factores como pendiente y distancia a la aguada (Holechek, 1988), puede generarse una herramienta que contribuye a mejorar nuestro conocimiento y manejo de las zonas áridas.

1.b. Uso de imágenes satelitales para la determinación de áreas homogéneas

En el análisis de imágenes satelitales, los métodos de clasificación permiten identificar y diferenciar tipos de cobertura o uso del suelo a partir de la información espectral contenida en cada píxel. La clasificación supervisada se basa en el entrenamiento del algoritmo con muestras de referencia previamente definidas por el analista, lo que permite una asignación más precisa de clases conocidas, aunque requiere conocimiento previo del área de estudio. En contraste, la clasificación no supervisada agrupa los píxeles en clases según sus similitudes estadísticas sin necesidad de información de campo inicial, lo que resulta útil en estudios exploratorios, aunque las clases obtenidas deben interpretarse y asignarse posteriormente (Garcia, 1997) La elección entre un enfoque supervisado o no supervisado depende de los objetivos del análisis, la disponibilidad de datos de entrenamiento y el nivel de detalle requerido.

Se han desarrollado numerosas técnicas de clasificación a lo largo de los años; entre aquellas que utilizan el píxel como unidad básica de análisis, se encuentran técnicas no supervisadas (por ejemplo, *K-means* e *ISODATA*) y técnicas supervisadas (es decir, *Maximum Likelihood*, *Minimum Distance*, *Artificial Neural Networks*, *Decision Trees*, *Support Vector Machines* y *Random Forests*) (Wulder *et al* 2018). Entre las técnicas supervisadas no paramétricas ampliamente utilizadas se

encuentran el aprendizaje automático, en particular *Random Forest* y *Support Vector Machines*.(Mancino *et al*,2023)

Random Forest, presenta antecedentes de desempeño superior en estudios comparativos dada por su menor sensibilidad al número total de muestras de entrenamiento y su balance, es decir la cantidad de muestras por clase y facilidad de aplicación en cuanto a los parámetros operativos previos (Maxwell *et al*, 2018;Perez *et al*, 2020). *Random Forest* se recomienda como una buena primera opción para clasificaciones, dada su estabilidad, facilidad de uso y tiempos de procesamiento (Genbatu *et al*. 2020). Si bien la investigación bibliográfica no arroja resultados positivos respecto a trabajos científicos donde se aplique *Random Forest* a situaciones de diferenciación de coberturas en zonas áridas, sí existen trabajos que buscan discriminarlas, de otras zonas, como áreas bajo riego, zonas urbanas, tierras no cultivables (Genbatu *et al*, 2020; Perez *et al*;2020).

Hoy existe acceso libre y gratuito a imágenes satelitales; computadoras portátiles cuentan con hardware de mayor capacidad de procesamiento para la ejecución de software de Sistemas de Información Geográfica (SIG) o (GIS por su sigla en inglés)(Mancino *et al*,2023), y existe software de tipo portable como es el caso de SAGA GIS (O.Conrad *et al*, 2015), que requieren menores recursos computacionales para operar, que otros software del mercado. SAGA GIS, constituye una herramienta accesible para los profesionales de las ciencias agropecuarias que tienen la necesidad de generar información geográfica para la comprensión integral de establecimientos agropecuarios.

Por otro lado, registrar información georreferenciada y de calidad con un importante grado de precisión a través de aplicaciones para teléfonos móviles que reciben varias constelaciones satelitales, significa que las herramientas para determinar las áreas homogéneas en campos de zona árida, son cada vez más accesibles, para poder elaborar información que impacte significativamente en el manejo de un establecimiento ganadero (Blanco *et al*. 2020) .

El desafío consiste en ajustar técnicas que permitan determinar con precisión las superficies, para lograr así un ahorro significativo de tiempo. Mediante procedimientos de clasificación supervisada, cuando se emplean datos de

entrenamiento para el algoritmo que se aplica, o no supervisada cuando se recurre a un agrupamiento de los datos sin datos de entrenamiento, agrupando en conjunto o no datos provenientes de diferentes bandas registradas por satélites, con índices derivados de ellas, se han logrado en muchos casos identificaciones exitosas. Estos algoritmos se ajustan con técnicas de refinamiento, filtrado y reagrupamiento de clases para alcanzar una clasificación de precisión aceptable. En ocasiones, este proceso requiere validaciones con nuevas visitas al terreno (Torre, 2022; Comisso, 2022; Blanco *et al.*, 2020; Perez *et al.*, 2020).

1.c. Determinación de áreas homogéneas aplicada a la evaluación forrajera de sistemas pastoriles extensivos

La utilización de imágenes satelitales permite identificar y cuantificar con precisión la cobertura de áreas homogéneas de vegetación, asociando productividades forrajeras a las mismas (Blanco *et al.* 2020). La información obtenida, junto con registros de precipitaciones, ocupación de los potreros y condición corporal de los animales, permiten programar usos y descansos de los mismos.

La delimitación de áreas homogéneas permite, precisamente determinar que tan homogéneo o similar es un determinado potrero. Sobre todo en lotes de gran superficie, el análisis satelital facilita la detección, mapeo y cuantificación de zonas con diferente disponibilidad forrajera, áreas de diferente composición forrajera, accesibilidad (por cobertura y densidad de leñosas). También son factibles de detectar e identificar sitios con presencia de especies invasoras o con menor cobertura vegetal.

En este caso, la determinación de áreas homogéneas de vegetación, es un tema de interés para la familia propietaria del establecimiento, particularmente para estimar la cobertura y posible expansión de *Hyalis argentea* “olivillo”, una especie de baja preferencia por parte del ganado bovino. *Hyalis argentea* se encuentra cubriendo grandes extensiones en el establecimiento, comúnmente en la cima de médanos. En algunos potreros con menor presencia de arbustos, domina el paisaje. Cubre áreas importantes, donde tiende a dominar el espacio, en perjuicio de gramíneas de mayor preferencia. Un incremento de cobertura por parte de *Hyalis argentea*, tendría un

impacto negativo en la capacidad de carga (EV/ha)¹ del establecimiento. Se estima que la propagación de *Hyalis argentea*, puede estar relacionada a eventos de fuego, que remueven la competencia de especies arbustivas (Guevara *et al*;1999; Passera *et al*;2007; Cesca *et al*; 2014). Corvalan *et al*, 2007; evaluaron su uso como forrajera, en un ensayo con vacas secas, con una carga de 0,88 cabezas/ha y suplementación nitrogenada, concluyendo que el olivillo es una especie seleccionada por los animales, por lo que solo es consumida cuando la presión de pastoreo se incrementa. En este sentido, cada evento de fuego determina un área homogénea (producida por el incendio), que se plantea evaluar en cada uno de los eventos determinados.

La receptividad ganadera ha sido definida como la densidad máxima de animales que puede mantenerse en un área determinada, en un cierto nivel de producción, sin deteriorar el recurso. Al definir la receptividad ganadera de un ecosistema dado se deben observar varias precauciones: una selección cuidadosa de los mejores métodos para cada objetivo particular y región, una actitud conservadora, un monitoreo continuo del estado de la vegetación y de la producción individual de los animales en relación a los objetivos productivos (ningún cálculo que afecte negativamente alguna de esas variables puede considerarse sustentable), y una actitud flexible para modificar la densidad ganadera bajo condiciones climáticas particulares, de manera de promover los procesos regenerativos o prevenir transiciones a estados más degradados (Golluscio,2009). Un enfoque en línea con los conceptos anteriores, recurre a la presupuestación forrajera con identificación de áreas homogéneas que pueden identificarse dentro de un campo, con el fin de determinar con precisión su superficie, estimar su productividad forrajera y con ello realizar un ajuste de la carga animal. (Blanco *et al*, 2020)

2. OBJETIVOS E HIPÓTESIS

2.a. OBJETIVO GENERAL

Aplicar un procedimiento basado en imágenes satelitales (IS) y Machine Learning para la determinación de áreas homogéneas en ambientes ganaderos del sur de Mendoza.

¹ Equivalente Vaca (EV): Equivalente ganadera que representa los requerimientos nutricionales de una hembra bovina que gesta, pare y cría un ternero hasta los 6 meses de edad o 120 Kg de peso.

2.b. OBJETIVOS ESPECÍFICOS

- Comparar métodos que afectan la precisión de procesos de clasificación de IS para determinar áreas homogéneas.
- Analizar el régimen de incendios a partir de análisis multi-temporal de imágenes satelitales.
- Analizar el impacto del régimen de incendios sobre los patrones espaciales de las áreas homogéneas actuales.

3. Hipótesis:

La aplicación de Machine Learning a la clasificación de imágenes satelitales permite determinar zonas homogéneas de comunidades vegetales en campos ganaderos de zonas áridas y establecer posibles relaciones con eventos que las modifiquen.

4. Material y Método:

4.a. Sitio Experimental

El estudio se realizó en “El Bagual”, establecimiento ganadero bovino, al norte del departamento San Rafael (-34.3680;-68.3749; Figura 1), ubicado en el espacio delimitado por la RN 143 al Oeste y la RP 153 al Este. Al Norte encuentra uno de sus límites en el Arroyo Seco Las Peñas y al Sur con el Arroyo Seco “La Hedionda”. Cuenta con 35.165 ha divididas en 11 potreros (Figura 2).




Figura N°1- Ubicación relativa establecimiento “El Bagual” en la provincia de Mendoza, Argentina




Figura N°2- Establecimiento “El Bagual”. Imagen Sentinel 2-A en composición Falso Color (Bandas 8 (infrarrojo cercano), 4 (rojo) y 3 (verde); con la división y numeración de potreros. Los círculos celestes y blancos representan la ubicación de las aguadas

Adquirido por la familia Pietrelli a fines de la década de 1990, el mismo fue destinado a la cría y recría bovina. Los registros de precipitaciones cuentan con datos continuos desde 2014 al presente, con un promedio por ciclo productivo (Jul-Jun), de 365 mm, con un mínimo de 171 mm en el ciclo 2019-2020 y un máximo en el ciclo 2015-2016 con 791 mm (Gráfico 1).




Gráfico N°1- Precipitaciones anuales(Jun-Jul) en mm y promedio de establecimiento “El Bagual” por ciclo productivo.

Fitogeográficamente, el establecimiento pertenece a la provincia del Monte (Cabrera, 1971), compuesto principalmente por especies arbustivas donde predominan los géneros *Larrea*, *Neltuma* y *Ephedra*. El estrato herbáceo lo componen especies del género *Aristida*, *Panicum*, *Setaria*, *Bouteloa*, *Sphaeralcea* y *Hyalis*.

El estrato arbóreo es casi inexistente, pero se registran individuos aislados de retamo *Bulnesia retama* o algarrobo *Neltuma flexuosa*.

Dentro de la fitogeografía provincial, se encuentra dentro de la denominada llanura este de la provincia, con suelos de textura arenosa, que forman médanos fijos de gran altura, generalmente dominados por *Hyalis* o *Panicum* (Roig et al; 2000)

Desde Octubre de 2020, la familia Pietrelli desarrolla tareas conjuntas de monitoreo de vegetación y manejo del rodeo de cría bovina, con el equipo de la Cátedra de Zootecnia y Granja de la Facultad de Ciencias Agrarias UNCuyo. El trabajo conjunto apunta a determinar pautas de manejo del rodeo bovino y monitoreo de la oferta forrajera, como sustento para decisiones de manejo.

“El Bagual” cuenta desde el año 2014 al presente, con registros de carga precisos. Previo a esta situación, sólo testimonios de la existencia de hasta 2000 cabezas en el campo, que asociada a bajas precipitaciones, produjo un severo sobrepastoreo. A su vez, la rotación de los potreros puede no haber sido adecuada, lo que ha provocando altas presiones de pastoreo por períodos prolongados, que llevó a la degradación de los ambientes

Por otro lado, una porción del campo, correspondiente a los potreros 8, 9, 9B y 10, totalizando 12.800 ha, fue arrendada desde el año 2007 al 2020, desarrollando en ella ganadería de cría, con una carga animal de 10 Ha/EV. Tal proyecto no registró buenos resultados económicos para el arrendatario, que tuvo pérdidas severas por mortandad de animales, produciendo un intenso sobrepastoreo, hecho que llevó a la finalización del proyecto en el año 2020

En esos años agravados por sequía severa el campo se encontró en una situación de exceso de carga y deterioro de su recurso forrajero, observada por el equipo de trabajo de la Facultad de Ciencias Agrarias UNCuyo.

En la figura N°2, se realiza una descripción del campo en sus potreros y la nomenclatura correspondiente. La imagen corresponde al mes de diciembre de 2024 y se realizó una composición denominada falso color con las Bandas 8 (Infrarrojo Cercano), 4 (rojo) y 3 (verde), asignando los colores rojo, verde y azul respectivamente. De esta forma, la vegetación en activo crecimiento, se destaca con colores rojizos, por lo que podemos inferir mayor actividad vegetativa en tales sitios. Las áreas con mayor cobertura, toman un color oscuro, casi negro, similar a cuerpos de agua, lo cual sería indicativo de alta cobertura y vegetación en activo crecimiento. Las áreas blancas son indicadoras de suelo desnudo o baja cobertura, típico de caminos o lecho de ríos secos

En las 22.000 ha de potreros manejados por la familia desarrolló su proyecto de cría, con los siguientes resultados productivos que se sintetizan en la tabla 1.

Tabla N°1- *Datos productivos del rodeo de cría de establecimiento “El Bagual”: vientres tactados, preñados, porcentaje de preñez, lluvias por ciclo productivo, porcentaje de destete y carga animal (ha/EV)*

Año	Tactados	Preñados	% Preñez	Lluvias (mm)	%Destete	ha/EV
2014	724	659	91	Sin Dato	83	30.3
2015	853	801	94	365	86	25.7
2016	811	674	83	791	78	27.1
2017	819	606	74	348	70	26.8
2018	838	703	84	291	80	26.2
2019	695	322	47	290	46	31.6
2020	501	371	74	171	72	44
2021	430	419	97	438	91	51
2022	417	400	96	402	94	52
2023	490	325	66	186	60	45

4.b. Procesamiento de datos satelitales para la determinación de áreas homogéneas

4.b.1. Software utilizado

Para el procesamiento de las imágenes, se utilizó el *software* SAGA GIS. Su sigla refiere a *System for Automated Geoscientific Analyses*. Este sistema de información geográfica (SIG) o (GIS) en inglés es gratuito, de fuente abierta y portable, diseñado para la aplicación sencilla y efectiva de algoritmos espaciales, con un catálogo integral de métodos geocientíficos. Su descarga es rápida y ocupa menos de 100 MB de espacio de disco. Fue obtenido del sitio <https://sourceforge.net/projects/saga-gis>. Dentro de las herramientas de análisis geoespacial disponibles, en SAGA GIS existen múltiples algoritmos de clasificación supervisada.

4.b.2. Elección del sensor

Las imágenes satelitales son una herramienta que desde su aparición, hace aproximadamente 50 años, han mejorado la comprensión de los sistemas naturales del mundo y esto no ha sido menor en zonas áridas. En sus inicios, los recursos computacionales no eran tan accesibles como lo son actualmente, donde quien lo desee puede instalar un software GIS en su computadora personal y con cierto entrenamiento realizar procesamiento, elaborar índices y correlacionarse con información de campo. El acceso a los catálogos de imágenes se realizaba por intermedio de organismos especializados y, hasta el aumento en los anchos de banda de los servicios de internet, las imágenes se enviaban a los usuarios en soporte físico, como cintas o discos compactos. Actualmente, el usuario final puede registrarse en un servidor de imágenes y obtenerlas directamente a su computadora. El análisis en sus inicios era mayormente visual, ya que el análisis profundo, la elaboración de índices espectrales y otras funciones, debían solicitarse a técnicos especializados, por lo que el ida y vuelta entre técnicos de campo y especialistas podía alargar el proceso de análisis (Chuvieco, 1995).

En este periodo de tiempo, las misiones satelitales han mejorado significativamente su resolución espacial, temporal y espectral, generando un enorme caudal de información disponible para caracterizar la cobertura terrestre. Dentro de las misiones satelitales dedicadas a la observación terrestre, se destaca la constelación Sentinel-2 para la caracterización de usos y coberturas del suelo en zonas áridas debido a una combinación de factores que las hacen particularmente adecuadas para este tipo de entornos (<https://sentiwiki.copernicus.eu/web/s2-mission>).

- **Alta resolución espacial:** Sentinel-2 ofrece una resolución espacial de hasta 10 metros en algunas de sus bandas, lo que permite un nivel de detalle suficiente para identificar y delimitar diferentes tipos de cobertura en zonas áridas, donde la heterogeneidad espacial puede ser alta. Esto es crucial para distinguir entre suelo desnudo, vegetación dispersa, lechos de ríos secos y otras características importantes de estos ecosistemas.
- **Cobertura espectral:** Sentinel-2 cuenta con 13 bandas espectrales que abarcan desde el visible y el infrarrojo cercano hasta el infrarrojo de onda corta (Tabla 2). Esta amplia gama de bandas permite una mejor discriminación de diferentes

tipos de suelo y vegetación, incluso en zonas áridas donde la vegetación es escasa y a menudo presenta respuestas espectrales similares. Bandas específicas, como las del infrarrojo de onda corta, son sensibles al contenido de humedad, lo cual es crucial en zonas áridas.

- **Alta resolución temporal:** Con un tiempo de revisita de 5 días con dos satélites en órbita (Sentinel-2A y Sentinel-2B), se obtiene una alta frecuencia de observación. Esto es crucial para monitorear los cambios en la cobertura del suelo a lo largo del tiempo, como la respuesta de la vegetación a las lluvias esporádicas, la expansión de áreas desertificadas o la evolución de proyectos de restauración.
- **Acceso libre y gratuito:** Los datos de Sentinel-2 son de acceso abierto y gratuito para cualquier usuario, lo que facilita su uso en investigaciones científicas, gestión ambiental y otras aplicaciones. Esto facilita el acceso a información valiosa para el estudio y la gestión de zonas áridas.
- **Complementariedad con otros sensores:** Los datos de Sentinel-2 pueden complementarse con información de otros sensores, como Landsat 8, para obtener una perspectiva aún más completa y realizar análisis multitemporales a largo plazo.

En resumen, las imágenes de Sentinel-2 ofrecen una combinación única de resolución espacial, espectral y temporal, junto con acceso libre y gratuito, lo que las convierte en una herramienta invaluable para la caracterización y el monitoreo de los usos y coberturas del suelo en zonas áridas, permitiendo una mejor comprensión y gestión de estos ecosistemas frágiles.

Tabla N°2: Bandas satelitales de Sentinel 2 A utilizadas para la clasificación, longitudes de onda en micrómetros y resolución espacial de las bandas en metros (m)

Banda	Longitud de Onda (µm)	Resolución Espacial (m)
Banda 2- Azul	0.43-0.45	10
Banda 3- Verde	0.45-0.52	10
Banda 4- Rojo	0.54-0.57	10
Banda 5- Rojo	0.69-0.71	20
Banda 6- Ultrarrojo	0.73-0.74	20
Banda 7- Rojo lejano	0.77-0.79	20
Banda 8- IR cercano	0.78-0.90	10
Banda 8A- IR cercano 2	0.85-0.87	20
Banda 11- SWIR 1	1.56-1.65	20
Banda 12- SWIR 2	2.1-2.28	20

Para el análisis de las zonas homogéneas se utilizaron imágenes satelitales Sentinel 2 obtenidas del sitio www.browser.dataspace.copernicus.eu.

Se descargaron 4 imágenes satelitales, dos T19HEB y dos T19HEC, de dos fechas: 10/12/24 (verano) y 18/08/22 (invierno). Las mismas se obtuvieron en el nivel L2A, lo que significa que se encuentran ortorectificadas con niveles de reflectancia por debajo de la atmósfera (BOA).

La elección de las fechas de las imágenes se realizó con el criterio de contar con una fecha en la cual la expresión vegetativa fuese importante, lo cual se cumplió en la primavera verano 2024, dado el aporte atípico que generaron las precipitaciones. Por otro lado, la imagen de invierno se seleccionó en base al análisis previo de imágenes de Google Earth de alta resolución, donde se observaba una buena diferenciación de las áreas con cobertura de *Hyalis* en los meses de invierno de 2022.

4.b.3. Selección de áreas de entrenamiento

Cada comunidad vegetal se identificó en los potreros del campo, según posibilidades de acceso, georeferenciando las muestras mediante la aplicación *Mobile Topographer*™ para teléfonos celulares. La app permite la toma de coordenadas GPS utilizando varias constelaciones satelitales con precisiones de hasta 0.5 metros. La app permite posteriormente la exportación de los datos en varios formatos, entre ellos csv (*comma separated values*) o txt (texto), los cuales pueden ser tomados por el software SAGA GIS utilizado en este trabajo. Las comunidades vegetales se definieron de acuerdo a la clasificación propuesta en la tabla N°3.

Tabla N°3- *Clasificación fisonómica de áreas homogéneas y descripción de los caracteres diferenciales*

Comunidad	Descripción
Arbustal Cerrado	Los arbustos representan la principal cobertura (mayor al 50%) con superposición de copias entre individuos. Estrato herbáceo escaso o inexistente
Arbustal Abierto	Arbustal representa menos del 50% de la cobertura, disperso, sin superposición de copias. Estrato herbáceo frecuentemente dominado por <i>Aristida mendocina</i>
Arbustal con Olivillo	Arbustal abierto con dominancia de olivillo en el estrato herbáceo
Olivillo	Ausencia de estrato arbustivo con total dominancia del estrato herbáceo por parte de <i>Hyalis argentea</i>
Pastizal	Domina el paisaje <i>Aristida mendocina</i>
Suelo desnudo (SD)	Sectores sin ningún tipo de cobertura vegetal o con algunos individuos arbustivos dispersos

El análisis de los puntos relevados en los diferentes potreros, contribuyó a formar una clasificación fisonómica de las comunidades vegetales presentes en el campo, posiblemente susceptible de ser detectada con precisión a través de clasificación supervisada. En primer lugar se tomó como criterio para denominar la comunidad vegetal o área homogénea, el tipo de estrato dominante del paisaje: arbustal,

herbáceas, gramíneas o bien suelo desnudo. Para las áreas de arbustal se buscó definir un atributo referente a su densidad, denominando abierto o cerrado en base al grado de densidad de individuos y su proximidad, caracterizando como cerrado en caso de existir una cobertura de arbustos superior al 50% y superposición de copas entre individuos y abierto en el caso donde la cobertura de arbustos fuese menor al 50% y los individuos se encontrarán dispersos en el espacio.

Por otra parte, como la familia propietaria plantea con particular énfasis su preocupación sobre aquellos sectores cubiertos por “olivillo” *Hyalis argentea*, en la clasificación de las áreas homogéneas se dió especial detalle a esta situación.

4.b.4. Métodos de clasificación

La clasificación supervisada para determinar áreas homogéneas, puede sintetizarse, como la aplicación de un algoritmo de clasificación, al cual se le otorga información georreferenciada de entrenamiento, puntos o polígonos, indicando a qué área homogénea pertenecen dichos puntos o polígonos.

A los fines de este trabajo, se propuso la comparación de dos métodos de clasificación supervisada, uno paramétrico, *Maximum Likelihood (ML)* y otro no paramétrico o denominado de aprendizaje automático, *Random Forest (RF)*, basado en el uso de múltiples árboles de decisión para clasificar los datos por voto mayoritario, tomando una muestra de datos inicial de forma aleatoria e independiente de los otros árboles de decisión. (Breiman, 2001). La diferencia entre los métodos paramétricos y no paramétricos reside en que en los primeros se considera conocida la función densidad de probabilidad de las clases, comúnmente de distribución normal o gaussiana. En los métodos no-paramétricos se ignora las funciones densidad de probabilidad que caracterizan las clases, siendo necesario un paso previo para la estimación de las funciones de probabilidad a partir de las muestras. (García, 1997)

Se muestrearon puntos en cada zona, destinando el 75% de los puntos al entrenamiento de los algoritmos, que busca características que le permita diferenciarlos. (Genbatu *et al.* 2020; Comiso, 2022; Torre Azzaroni, 2022; Pérez *et al.*, 2020)

Los algoritmos procesan la información de las bandas satelitales ingresadas y producen una clasificación a partir de esta información de entrenamiento. Una vez

entrenado, procesa el resto de los puntos asignándoles una clase o categoría acorde a su entrenamiento previo. Luego, la clasificación obtenida se evaluó por medio de una matriz de confusión, con el 25% de los puntos restantes, los cuales no deben haber sido insumo para entrenamiento del algoritmo. Luego se contrasta la clasificación obtenida con la realidad del campo, superponiendo la clasificación en imágenes de alta resolución, con el fin de evaluar su precisión y la necesidad de reclasificar zonas incorrectamente clasificadas. Se busca valores de precisión general, de usuario y productor, superiores a 0,9 así como un coeficiente Kappa de 0.8 a 1, como indicadores de la capacidad predictiva de las clasificaciones obtenidas

4.b.5. Procedimientos aplicados: Maximum Likelihood y Random Forests

Las bandas de Sentinel 2, con resolución espacial de 20 metros, fueron ajustadas mediante la función *Resampling* a resolución espacial de 10 metros. Posteriormente se conformó un mosaico para cada banda proveniente de las dos imágenes T19HEB y T19HEC, con el fin de abarcar la totalidad de superficie del establecimiento en una sola imagen de cada fecha.

Mediante un archivo *shape* del perímetro completo del campo, se procedió al recorte de las bandas de cada fecha para ajustar el análisis a la zona de interés.

Los puntos provenientes de los relevamientos a campo, se exportaron en formato tabla a SAGA. Los puntos fueron relevados según las posibilidades de acceso al establecimiento, en los alrededores de picadas accesibles al momento de la visita. Al momento del muestreo se verificó que cada clase muestreada tuviese, aproximadamente, una superficie mayor a 100 metros cuadrados (10 m x 10 m, 1 pixel). Se destaca en la tabla N°4 un desbalance en la cantidad de clases y puntos relevados para cada una. Se decidió conservar este desbalance, dado que refleja la realidad de las áreas del campo y según Maxwell *et al* (2018), Random Forest sería insensible al desbalance en el muestreo de clases, situación que se daría frecuentemente en este tipo de trabajos, donde las clases con mayor superficie tendrán tendencia a contar con mayor número de puntos.

Ejemplo de la situación antes descrita, son las clases suelo desnudo (SD) y pastizal, de escasa superficie detectada previamente. Durante el relevamiento a campo, para

la clase suelo desnudo (SD) se relevaron 6 puntos en total, dos de ellos agregados posteriormente por extracción desde imagen de alta resolución (lecho de ríos secos), para asegurar un número mínimo de 3 puntos de entrenamiento y 3 puntos para verificación (Tabla N°4).

Tabla N°4- *Cantidad de puntos georreferenciados relevados por cada zona homogénea y partición de los mismos con destino a entrenamiento o validación de las clasificaciones.*

Comunidad	Entrenamiento	Validación	Total
Arbustal Cerrado	11	3	14
Arbustal Abierto	48	14	62
Arbustal con Olivillo	23	7	30
Olivillo	40	12	52
Pastizal	3	3	6
Suelo Desnudo	3	3	6
Total	128	42	170
Porcentaje	75%	25%	100%

En gabinete, se ajustó la nomenclatura de los puntos relevados según la pertenencia a cada una de las 6 comunidades vegetales de interés, obteniendo en total 170 puntos. Los mismos se destinaron, aproximadamente, 75% al entrenamiento del algoritmo Random Forest y el 25% restante se utilizó luego para la verificación mediante matriz de confusión (Torre, 2022; Comisso, 2022; Perez *et al*, 2020; Maxwell *et al*. 2018) . Se denominan puntos de entrenamiento, a aquellos que se ingresan como parámetros al algoritmo y validación a aquellos utilizados para realizar la matriz de confusión entre la clasificación obtenida y datos de campo verificados.

Utilizando la función *Shapes Buffer* los puntos se convirtieron en polígonos de entrenamiento, la cual generó un polígono circular de radio a elección, en este caso 10 metros de radio. Este polígono toma los valores de los píxeles cuyos centros se encuentran dentro del radio y luego considera sus valores para el entrenamiento y

clasificación. La misma operación se repitió para los puntos de validación, por lo cual la clasificación y validación no se basaron en los valores obtenidos en un solo píxel, sino para un grupo de píxeles cuyos centros coinciden en el área de influencia del polígono.

SAGA, cuenta con una versión del algoritmo *Random Forest* denominada *Open CV*, la cual permite ajustar parámetros antes de iniciar la clasificación: máxima profundidad del árbol, número mínimo de muestras y número máximo de categorías. A los fines de este trabajo, los mismos se conservaron en la configuración original o default.

Tabla N°5- *Parámetros disponibles para su ajuste en la clasificación Random Forest Open CV de SAGA GIS y sus valores predeterminados o default*

Parámetro	Valor default
Máxima profundidad árbol	10
Número mínimo muestras por nodo	2
Máximo categorías	10

Se realizó una clasificación *Maximum Likelihood*, utilizando las mismas áreas de entrenamiento y verificación, a modo de comparación. *Maximum Likelihood*, es un clasificador de los denominados paramétricos, ya que asume que los valores de reflectancia espectral de cada clase en las diferentes bandas de la imagen siguen una distribución normal (Garcia, 1997). Ambos clasificadores, se seleccionan debido a la simplicidad en la definición de sus parámetros de procesamiento, sin requerir conocimientos profundos en la materia o de las variables a clasificar.

Posterior a la clasificación, se aplicó un filtrado de mayoría a las clasificaciones para eliminar el efecto *speckle* o salpicado. Este efecto se debe sintéticamente al tratamiento independiente de los valores de cada píxel, por parte de los algoritmos de clasificación, que no tiene en cuenta la clasificación de los píxeles vecinos. Así en el resultado de la clasificación, pueden aparecer píxeles clasificados, dispersos aleatoriamente, dando la apariencia de salpicaduras en la clasificación. El filtro por mayoría, toma una ventana de tamaño definido por el usuario, en este caso de 3x3

pixeles, la cual se desplaza por la imagen, reasignando pixeles aislados o poco significativos.

Posterior a la aplicación del filtrado, utilizando los puntos reservados para validación, se realizará para las clasificaciones obtenidas la matriz de confusión, mediante la función *Confusion Matrix* de SAGA. La tabla resultante, resume y visualiza el desempeño de un modelo al comparar las predicciones con los valores reales. Es una tabla de dos dimensiones, donde se representan

Filas: Representan las clases reales (las etiquetas verdaderas de los datos), clasificadas a campo.

Columnas: Representan las clases predichas por el modelo.

De ella pueden evaluarse las precisiones generales, de productor y usuario (Congalton, 2001)

Precisión general: se obtiene por la división del número total de píxeles clasificados correctamente por el número total de píxeles en la matriz

Precisión de usuario: se obtiene dividiendo la cantidad de píxeles correctamente clasificados para un área homogénea sobre el total de píxeles de la fila. Es un estimador de la probabilidad de que un punto determinado pertenezca en validación a campo, al área homogénea clasificada.

Precisión de productor: se obtiene dividiendo la cantidad de píxeles correctamente clasificados para un área homogénea, sobre el total de píxeles de la columna. Es un estimador de la probabilidad de un píxel de ser correctamente clasificado por el algoritmo y representa una medida del error de omisión.

Coeficiente Kappa: compara la exactitud observada (OA) con la exactitud que se esperaría al azar. Es una medida de cuán confiable es una clasificación respecto a una asignación aleatoria de clases. Según Landis y Koch (1977), valores superiores a 0.81 indican un acuerdo casi perfecto

Es posible la necesidad de un ajuste de las clasificaciones a pesar del logro de altas precisiones de clasificación. Para ello, recurriendo a datos de campo y contraste con imágenes de alta resolución, puede verificarse la confiabilidad de la clasificación y reasignar aquellas áreas incorrectamente clasificadas.

4.c. Análisis de series temporales de imágenes satelitales para determinar el régimen de incendios

Las sucesivas recorridas y los cambios de paisaje tan importantes que pueden observarse al transitar “El Bagual”, plantean la pregunta sobre los factores que determinaron dichos cambios. En consecuencia, y en la búsqueda de dar una explicación a la detección de áreas homogéneas algo atípicas a la vegetación común de la región, se realizó un relevamiento histórico de imágenes satelitales. Es probable que uno de los factores relevantes, con una fuerte influencia en las zonas áridas, es la ocurrencia de incendios (Cesca *et al*, 2014), por lo que se realizó un relevamiento de sus ocurrencias.

Para investigar la posible influencia del fuego en el establecimiento “El Bagual”, se realizó una búsqueda en repositorio web de imágenes satelitales, Earth Explorer USGS (<https://earthexplorer.usgs.gov>) de la zona, con nubosidad inferior al 10%, de los satélites Landsat 4-5 TM (Thematic Mapper). Se obtuvieron imágenes desde 1984 al 2000, donde pudo verificarse la ocurrencia de 3 eventos de fuego: primavera 1984, verano 1986 y verano 2000. Las fechas de los eventos son estimadas ya que el tiempo de revisita de los satélites es de 18 y 16 días respectivamente, y al momento de revisita, las condiciones de nubosidad, no siempre fueron óptimas sobre la zona del campo, por lo que pudo estimarse la fecha de los eventos a un rango de tiempo aproximado en meses.

Utilizando el software SAGA GIS™, se obtuvieron las combinaciones de bandas de color real (*RGB composite*), detectando las áreas quemadas de cada uno de los eventos. Aplicando la función *Object Based Image Segmentation* se obtuvo una segmentación de la imagen en polígonos, agrupando aquellos que corresponden a áreas quemadas para cuantificar su superficie, que fueron fácilmente detectables por la apreciable diferencia entre el suelo desnudo, afectado por el fuego y lo no afectado por el fuego, cubierto de vegetación.

Una vez cuantificadas las superficies dentro de cada área de incidencia de eventos de fuego, se realizó análisis de correlación aplicando la correlación de Pearson.(Spiegel, 1992) y Sperman.

El análisis de la asociación entre las Clases Ambientales (unidades de observación, n=4 pares de datos por clase) y las Incidencias de Fuego (variable de afectación) se realizó en dos fases: la medición de la fuerza de la asociación y la prueba de significancia estadística.

1. Medición de la Fuerza y Dirección de la Asociación

Para cada clase ambiental, se calcularon dos coeficientes de correlación principales para evaluar diferentes tipos de asociación:

Coeficiente de Correlación de Pearson (r):

Objetivo: Medir la fuerza y dirección de la relación lineal entre la Incidencia de Fuego y la Proporción de Área Afectada.

Coeficiente de Correlación de Spearman:

Medir la fuerza y dirección de la asociación monótona (consistente en su dirección: ambas variables suben o ambas bajan) entre los rangos de las variables.

Es un método no paramétrico que se utiliza para detectar asociaciones no lineales o para manejar datos con posibles valores extremos . El cálculo se realizó aplicando el coeficiente de Pearson a los rangos de los datos originales.

5.Resultados y discusión

5.a. Clasificación de áreas homogéneas

5.a.1. Random Forest vs Maximum Likelihood: Invierno y Verano

Se obtuvieron los resultados de las clasificaciones por Random Forest y Maximum Likelihood, tanto para la imagen de 10/12/2024 (Verano) como para la de 18/08/2022 (Invierno). La aplicación de *Random Forest* (RF) y *Maximum Likelihood* (ML) en la imagen de invierno, arrojó niveles de precisión superiores a los de verano (Tabla 8).

Figura N°3- Resultados de clasificación por Random Forest (izquierda) y Maximum Likelihood (derecha) en base a la imagen de verano 2024. En cada imagen se lista su precisión general (OA) e índice Kappa




Figura N°4- Resultados de clasificación por Random Forest (izquierda) y Maximum Likelihood (derecha) en base a la imagen de invierno 2022. En cada imagen se lista su precisión general (OA) e índice Kappa




Figura N°5- *Clasificación Random Forest de la imagen de invierno 2022 ajustada*




Tabla N°8- Matrices de confusión de la clasificación por Random Forest Opencv y Maximum Likelihood en SAGA GIS de la imagen de invierno 2022, precisiones de productor y usuario, coeficiente Kappa y Precisión General

	Random Forest	Maximum Likelihood
Exactitud Global (OA)	97,4%	85,9%
Coeficiente Kappa	0,9398	0,8180
Exactitud Productor		
SD	97,32%	89,19%
Arb Cerrado	98,97%	94,59%
Arb Abierto	100,00%	80,23%
Arb con Olivillo	95,60%	65,43%
Olivillo	96,76%	93,67%
Pastizal	95,83%	100,00%
Exactitud Usuario		
SD	100,00%	86,84%
Arb Cerrado	100,00%	76,09%
Arb Abierto	93,67%	92,00%
Arb con Olivillo	97,03%	79,10%
Olivillo	98,35%	88,10%
Pastizal	100,00%	87,80%

Las matrices de confusión arrojan precisiones generales y un índice kappa. 97.4% y 0.94 para RF; y 85.9% y 0.81 para ML (Tabla 8) lo que indica una alta precisión en la clasificación (Congalton, 2001). Más allá de la alta precisión general lograda, es destacable el logro de altas precisiones de productor y usuario, superiores al 90%, por parte de RF a pesar de la disparidad de tamaños muestrales para cada clase, lo

cual según Maxwell *et al* 2018, puede ser un factor en contra del logro de altas precisiones.

Tabla N°9- Matrices de confusión de la clasificación por Random Forest Opencv y Maximum Likelihood en SAGA GIS de la imagen de verano 2024, precisiones de productor y usuario, coeficiente Kappa y Precisión General

	Random Forest	Maximum Likelihood
Exactitud Global (OA)	92,0%	23,4%
Coeficiente Kappa	0,8964	0,0316
Exactitud Productor		
Suelo Desnudo	81,08%	0,00%
Arb Cerrado	100,00%	27,03%
Arb Abierto	97,67%	0,00%
Arb con Olivillo	88,89%	0,00%
Olivillo	91,77%	43,67%
Pastizal	88,89%	63,89%
Exactitud Usuario		
Suelo Desnudo	96,77%	0,00%
Arb Cerrado	75,51%	13,16%
Arb Abierto	87,50%	0,00%
Arb con Olivillo	92,31%	0,00%
Olivillo	100,00%	35,20%
Pastizal	97,32%	14,11%

Tabla N°10- Resultados de la clasificación Random Forest de invierno y Random Forest ajustada para cada área homogénea

Área homogénea	Clasificación Random Forest		Clasificación Random Forest Ajustada	
	Sup (ha)	%	Sup (ha)	%
Arb Abierto	19091	55%	20091	58%
Arb Cerrado	1992	6%	4072	12%
Arb con Olivillo	8962	26%	5881	17%
Olivillo	3518	10%	3518	10%
Pastizal	709	2%	709	2%
Suelo Desnudo	430	1%	430	1%
Arb con Olivillo+Olivillo	12480	36%	9399	27%
Total (ha)	34701		34701	

Surge como observación, la necesidad de contar con un número mínimo de muestras por cada clase, recurriendo a un muestreo aleatorio en el terreno, ajustado a las posibilidades de acceso, o bien recurriendo al muestreo de clases con auxilio de imágenes de alta resolución en aquellos lugares donde no sea posible acceder físicamente (Torre Azzaroni; 2022). Sin embargo a los fines del trabajo y con técnicas suplementarias de reclasificación o reagrupamiento de clases, se compensan los errores de clasificación.

5.b. Determinación de zonas afectadas por eventos de fuego

Del análisis de las imágenes satelitales de Landsat 4 y 5 del periodo 1984-2000 se observaron claramente las zonas afectadas por el fuego (Figuras 3 y 4), estimándose las superficies mostradas en la Tabla N°6 y 7.

Tabla N°11 Fechas aproximadas de los eventos de fuego en establecimiento “El Bagual”, San Rafael Mendoza y cantidad de hectáreas afectadas

Fuego (fecha)	Primavera 1984	Verano 1986	Verano 2000
Superficie (ha)	7.191	18.186	32.240 ha




Figura N°6- De izquierda a derecha, superficies afectadas por los eventos de fuego de 1984,1986 y 2000 en establecimiento “El Bagual”, San Rafael, Mendoza




Figura N°7- Superficies del establecimiento “El Bagual” e incidencia de eventos de fuego en el periodo 1984-2000

Tabla N°12- Incidencia del fuego en el establecimiento “El Bagual”. Superficies afectada según cantidad de eventos de fuego en el periodo 1984-2000

N°Eventos	Superficie afectada (ha)
3	5.097
2	13.784
1	13.535
0	2.916

El fuego controla la fisonomía de la vegetación, llevando a una simplificación de la estructura de la vegetación (Cesca *et al.* 2014), lo que se verifica en el establecimiento ya que a mayor incidencia de eventos de fuego para el periodo analizado, se observa pérdida de especies y una menor cobertura de arbustos. Los sectores con nula o menor incidencia se pueden describir como arbustales densos a cerrados de jarilla, mientras que los sectores quemados hasta 3 veces, como arbustales abiertos o muy dispersos de alpataco o solupe, donde las especies dominantes del estrato herbáceo son *Aristida mendocina* o *Hyalis argentea*. Esta situación de disminución de superficie de arbustos e incremento de la superficie de gramíneas y herbáceas coincide con las observaciones registradas por Guevara *et al.* 1999.

Guevara *et al.* 1999, también reporta, 27 meses posterior a los eventos de fuego, un incremento de especies palatables, tanto en sitios pastoreados como sin pastorear. Tal situación puede haberse producido en el establecimiento “El Bagual”, pero a la fecha se verifica una dominancia de especies poco palatables para el ganado bovino, muy probablemente debida a efectos de sobrepastoreo.

5.c. Efecto del fuego sobre las áreas homogéneas

Se cruzaron los datos de las superficies afectadas por fuego con las superficies detectadas de las diversas zonas homogéneas, resultando de ello la cantidad y proporción de superficie afectadas por eventos de fuego para cada una de las áreas seleccionadas (Tabla N°11)

Tabla N°13- Porcentaje de superficie de cada clase de acuerdo a la incidencia de eventos de fuego en establecimiento “El Bagual” y coeficiente de correlación de Pearson

Clase	N° Eventos de Fuego				Correlación Pearson	Significancia ($\alpha=0.01$; n=4)
	0	1	2	3		
Arb Abierto	8%	83%	64%	51%	0,446	No significativo
Arb Cerrado	81%	5%	5%	7%	-0,761	No significativo
Arb con Olivillo	0%	0%	19%	15%	0,830	No significativo
Olivillo	15%	8%	8%	19%	0,284	No significativo
Pastizal	0%	1%	3%	3%	0,947	No significativo
Suelo desnudo	3%	1%	1%	3%	0,000	No significativo
Arb con Olivillo + Olivillo	15%	8%	27%	35%	0,845	No significativo

El análisis de la tabla N°11 indica una correlación positiva importante con la cantidad de eventos de fuego, de 0.845 para la suma de clases Arbustal con Olivillo y Olivillo y 0.83 para la clase Arbustal con Olivillo. No se verifica una correlación lineal fuerte para la clase olivillo. Existe una importante correlación negativa entre fuego y Arbustal Cerrado.

El propósito de la prueba de significancia fue determinar si los coeficientes de correlación (r y ρ) observados en la muestra ($n=4$) eran lo suficientemente grandes como para rechazar la hipótesis nula de que la correlación poblacional ($\rho_{\text{poblacional}}$) es cero.

Hipótesis:

Nula (H_0): No existe correlación significativa ($\rho_{\text{poblacional}} = 0$).

Alternativa (H_a): Sí existe correlación significativa ($\rho_{\text{poblacional}} \neq 0$). (Prueba bilateral).

Estadístico de Prueba: Se empleó la distribución t de Student con n grados de libertad = $4 - 2 = 2$ grados de libertad. El estadístico t se calculó a partir del coeficiente de correlación (r o ρ).

Nivel de Significancia (α): Se estableció un nivel de significancia estricto de 0.01

Criterio de Decisión:

Se determinó el Valor Crítico t crítico, 9.925 para $gl=2$ y $\alpha=0.01$.

La H_0 se rechazaría solo si el valor absoluto del $t_{\text{calculado}}$ fuera mayor que 9.925.

Resultado del Análisis: Debido al reducido tamaño muestral ($n=4$), el umbral de $\alpha=0.01$ resultó ser demasiado estricto, concluyendo que ninguna de las correlaciones observadas fue estadísticamente significativa bajo este criterio.

El coeficiente de Spearman evalúa la asociación monótona entre las dos variables. Una relación monótona significa que, a medida que una variable aumenta, la otra variable tiende consistentemente a aumentar (o consistentemente a disminuir), sin importar si la relación es una línea recta o una curva.

Tabla N°14- Tabla resumen de los coeficientes de Pearson (r) y coeficientes de Spearman (ρ) y medidas de significancia estadística del coeficiente de Spearman.

Clase	r de Pearson	ρ de Spearman	Fuerza de Correlación	Significancia ($\alpha=0.01$, $n=4$)
Pastizal	0,947	0,950	Fuerte Positiva	No Significativa
Arb con Olivillo + Olivillo	0,845	0,800	Fuerte Positiva	No Significativa
Arb con Olivillo	0,830	0,750	Fuerte Positiva	No Significativa
Olivillo	0,284	0,350	Débil Positiva	No Significativa
Arb Abierto	0,446	0,200	Débil Positiva	No Significativa
SD	0	0,100	Muy Débil Positiva	No Significativa
Arb Cerrado	-0,761	-0,250	Débil Negativa	No Significativa

El análisis de los valores de correlación concuerda con las conclusiones de Guevara *et al.* 1999 y Cesca *et al* 2014 sobre los cambios fisonómicos de la vegetación hacia una pérdida de estratos, e incremento de plantas herbáceas, con la consecuente pérdida de especies arbustivas de valor forrajero como *Atriplex lampa* acorde a lo verificado por Passera *et al*, 2007

Por otro lado esta hipótesis encuentra sustento en base a la información de dos publicaciones. Por un lado Tacchini *et al*, 2014 en su libro Ganadería Bovina de General Alvear, releva y clasifica los ambientes del departamento, informando una superficie de travesía o pastizal pampeano de 400.000 ha, dominados por olivillo (*Hyalis argentea*) y paja amarga (*Elionurus muticus*) en el sudeste del departamento. Esta zona coincide con la zonas identificadas por Villagra *et al*, 2024 , como zonas de alta recurrencia de incendios en el periodo 1985-2023

5.d. Receptividad ganadera - Impacto del Olivillo

Un resultado práctico de haber medido la superficie de cada una de las áreas homogéneas detectadas, es la posible estimación de las receptividades presentes y logrables con cambios sobre las mismas. Se realiza una estimación del impacto de la cobertura de olivillo, en base a las áreas homogéneas determinadas, en la receptividad del establecimiento

Tabla N°15- Estimación del impacto de la cobertura de olivillo en la receptividad de establecimientos “El Bagual”: escenario actual donde no se logra consumo de olivillo y escenario mejorado con un 50% de logro de consumo de olivillo

				Producción	% Aprovechamiento		
Área homogénea		Sup (ha)	Kg MS/ha	Actual	Kg MS utilizados	Mejorado	Kg MS utilizados
Arb Abierto		20091	253	50%	2541511,5	50%	2541511,5
Arb Cerrado		4072	200	50%	407190	50%	407190
Arb con Olivillo		5881	300	0%	0	50%	882195
Olivillo		3518	300	0%	0	50%	527688
Pastizal		709	400	50%	141766	50%	141766
SD		430	0	0%	0	0%	0
Total		34701			3090468		4500351
				Kg/ha	89		130
				EV	847		1233
				ha/EV	41,0		28,1

En la Tabla N°13 se muestra la receptividad actual estimada y la factible de lograrse un incremento del 50% en el aprovechamiento de las áreas homogéneas con presencia de olivillo. Bajo el escenario actual, observamos un impacto importante en la pérdida de receptividad, estimada en 386 EV menos por no aprovechamiento del olivillo. Van den Bosch *et al*, 1997, evalúa a *Hyalis argentea* como una forrajera de aceptable calidad, que forma parte de la dieta regular de los bovinos en el campo experimental “El Divisadero”, Santa Rosa. En “El Bagual” no es consumida por los bovinos, por lo que existe una oportunidad de aprovechamiento. Corvalan *et al*. 2007, reporta que en General Alvear, Mendoza utilizando una carga instantánea de 0.88 cabezas de vacas secas por hectárea, se logró el consumo de olivillo durante el invierno . En 127 Ha de olivillo, aportando suplemento proteico con urea a razón de 120 gramos por cabeza/día, se logró sostener la condición corporal de 112 vacas secas durante un periodo de 42 días .

5.e. Recomendaciones prácticas que surgen del análisis de la afectación producida por el fuego y de las áreas homogéneas determinadas

Dada la situación del establecimiento, donde se verifica un incremento de la superficie de olivillo asociado a la incidencia de eventos de fuego, la dominancia en el estrato gramíneo de especies de poca palatabilidad como lo es *Aristida mendocina*, es importante pensar en herramientas que conduzcan al aprovechamiento de estos recursos forrajeros. La superficie de los potreros y la cantidad de animales actualmente presentes en el campo, configuran una situación de carga instantánea que determina un pastoreo selectivo y el bajo aprovechamiento de estos recursos.

Generar presión de pastoreo, por mayores tiempos de permanencia en el potrero, sería posible pero con un perjuicio muy grande sobre la condición corporal de los animales. En lugar de extender los tiempos de pastoreo, lo sería el aumento de la carga instantánea mediante un pastoreo rotativo intensivo. Sería interesante analizar la posibilidad de realizar subdivisiones con boyeros eléctricos

permanentes, de aproximadamente unas 500 Ha, y posteriormente dentro de las mismas realizar subdivisiones con boyeros móviles, para alcanzar valores de carga instantánea de 10 animales/ha o superior. La posibilidad de llevar adelante estos cambios en establecimiento “El Bagual” se ve favorecida por el efecto de los incendios, que simplificaron la implementación de los boyeros eléctricos debido a la menor presencia de arbustos

Esta recomendación, implica un cambio importante en la gestión de los sistemas de zonas áridas, donde el pastoreo continuo y altas cargas son prácticas frecuentes (Guevara *et.al*,2009). Sin embargo, el logro de este manejo, tiene el potencial de ser una herramienta que a largo plazo signifique un aumento de carga general, de forma sustentable en sus tres dimensiones: social, ambiental y económica. Es la carga, un índice que tiene impacto directo sobre la producción total del campo, ya que el incremento marginal por cabeza, es mayor que aquellos incrementos que pueden producirse por mejoras en los índices productivos individuales del rodeo de cría. Por ejemplo, un rodeo de cría de 300 vientres, que incrementa un 10% su porcentaje de destete, del 70% al 80%, con 120 kg de peso al destete, registra un incremento marginal por cabeza de 12 Kg. En cambio, para un destete del 70% y 120 kg/destete, cada cabeza que pueda incorporarse reporta un incremento marginal de 84 Kg. Esto incrementa directamente la cantidad de materia seca que debe ofertar el campo, la cual se compensaría, por el incremento de eficiencia de cosecha, por el cambio de un pastoreo selectivo a un pastoreo no selectivo, con mayor índice de cosecha por hectárea. (Golluscio *et al*, 2009)

6. Conclusiones

Random Forest registra un resultado muy superior a Maximum Likelihood para la detección de áreas homogéneas con un alto porcentaje de precisión general, así como bajo porcentaje de error por omisión (precisión productor) y alta probabilidad de acierto en la verificación a campo (precisión usuario).

La clasificación obtenida en base a imágenes registradas en invierno, mostró mayor precisión dado que estuvo significativamente menos afectada por la cobertura efímera de anuales, lo cual afecta el comportamiento espectral de las comunidades identificadas.

El historial de fuegos demostró alta correlación negativa con la presencia del área arbustal cerrado y positivamente con las áreas homogéneas con alta cobertura de olivillo, debido a la eliminación de especies arbustivas que compiten con el estrato herbáceo o de gramíneas (Guevara et al

A los fines de clasificar coberturas en zonas áridas, es posible la aplicación de *Random Forest* para la diferenciación de áreas homogéneas. Se confirma su baja sensibilidad al desbalance de clases, dadas las características de los datos relevados para la definición de áreas homogéneas, logrando obtener altas precisiones a pesar de ello. Sin embargo, si se consiguiera realizar un muestreo balanceado de las áreas homogéneas a identificar, podría reflejarse en mejores resultados de clasificación. Esto evidencia que la clasificación de coberturas de suelo, es altamente sensible, siempre y en todos los casos, al conjunto de datos de entrenamiento (Maxwell *et al*, 2018).

Es importante destacar, que las características de las áreas homogéneas descritas y definidas en la Tabla N°3, fueron susceptibles de diferenciación con el uso de las imágenes de Sentinel, en la resolución espacial de 10 m, por lo que el criterio de definición aparenta estar correctamente ajustado. Este criterio resulta sencillo de aplicar, en el contexto de un muestreo a campo, que busca relevar información cubriendo rápidamente la mayor cantidad de terreno posible.

En síntesis, en base a este caso práctico, se puede concluir que la aplicación de *Random Forest* a la identificación de áreas homogéneas en zonas áridas es posible, constituyendo una aproximación inicial de alta precisión para el

conocimiento y monitoreo de estos sistemas naturales, utilizando sus resultados en la gestión de sistemas ganaderos.

A los fines de evaluar las técnicas empleadas en el presente trabajo y que aportaron a un resultado positivo, se pueden enumerar los siguientes factores:

1) SAGA GIS, se recomienda como software alternativo accesible y con menores requerimientos de hardware para su funcionamiento. Las herramientas necesarias para ejecutar clasificaciones, son rápidamente accesibles y de uso intuitivo.

2) Al momento de definir áreas homogéneas, para su posterior identificación con *Random Forest* en el campo, definir caracteres predominantemente fisonómicos antes que florísticos, de tipo cualitativo y fácil observación.

3) Respaldo el muestreo con el uso de imágenes de alta resolución (Google Earth), para identificar áreas homogéneas y complementar el muestreo a campo. De esta manera se puede incrementar el número de muestras, sobre todo para aquellas áreas de menor superficie. Por otro lado, de estar disponibles imágenes históricas, la visualización de las mismas puede contribuir significativamente a la selección de fechas de las imágenes satelitales para su procesamiento. Esta práctica encuentra respaldo en otros casos, como Torre Azzaroni, 2022; Comisso, 2022; Blanco *et al.*, 2020; Perez *et al.*, 2020; Maxwell *et al.* 2018

4) Registrar y considerar las condiciones del campo al momento de realizar el muestreo: precipitaciones, potreros pastoreados y en descanso, emergencia de especies anuales, fueron de particular importancia en la interpretación de los resultados de este trabajo. En este caso particular, donde se pone énfasis en la detección de olivillo, se logró mayor contraste entre áreas homogéneas en los meses de invierno, en relación con los meses de verano. Particularmente con una primavera lluviosa, donde el crecimiento de gramíneas y herbáceas, generan firmas espectrales similares.

Consideraciones finales:

Utilizar imágenes satelitales para la determinación de áreas homogéneas, es una herramienta cada vez más accesible para técnicos que se desempeñan en campo y deben respaldar decisiones importantes en información confiable. Interpretar y elaborar información proveniente de imágenes satelitales de establecimientos ganaderos de zonas áridas, constituye una excelente herramienta para una interpretación general de los sistemas. Hoy en día, la gran variedad de herramientas con las que cuentan los software GIS, permiten analizar múltiples decisiones con una perspectiva ampliada a la que permite la observación visual a campo, ya que podemos tener una vista del campo completo o un potrero determinado. Estos recursos en los últimos años, han mejorado su precisión, confiabilidad y disponibilidad . A su vez, el registro de información georreferenciada como la de las precipitaciones, por ejemplo, brinda una presentación superior y mejor ubicada en el espacio que la misma información presentada en una tabla. Con estos sencillos ejemplos, buscó destacar la importancia del recurso SIG o GIS, para tomar una mirada general de las zonas áridas. Entrenarse en estas herramientas, bien merece el tiempo de aprendizaje, ya que permitirán sustentar decisiones de una forma distinta y probablemente mejorarán los resultados. La aplicación de Machine Learning, puntualmente en este caso, Random Forest, con resultados de alta precisión en la determinación de ambientes, permitiendo el ajuste de carga del campo según el aporte forrajero de las diferentes áreas homogéneas, suma un contundente ejemplo más de la importancia de estas herramientas, y lo importante que es capacitarse en ellas para tomar decisiones con otra perspectiva.

Este trabajo, resuelve para la familia Pietrelli, una inquietud que tuvieron durante años, acerca de la superficie de olivillo en “El Bagual”. Establece un dato de superficie que lo cuantifica y establece una línea base para monitorear su posible avance en el futuro. La posibilidad de observar en un mapa del campo, la superficie de olivillo, revela su magnitud en cada potrero y significa la posibilidad de modificar

el pensamiento: del olivillo como amenaza, a un recurso subexplotado y buscar formas de aprovecharlo, pensando en proyectos de pastoreo intensivo.

Las imágenes satelitales son registros objetivos a lo largo del tiempo, que en conjunto con valoraciones a campo, permiten inferir condiciones de un campo. Son una excelente herramienta para la evaluación rural para compra o arrendamiento. En todos los casos, se puede acceder a una limitada superficie del campo, identificar áreas homogéneas que lo componen, identificar lugares en buena condición, regular o degradados, y luego basado en imágenes satelitales, realizar una aproximación de la condición del campo para los objetivos de un proyecto determinado. Nuevamente esto plantea una perspectiva general y no sesgada a la recorrida parcial. La situación bien puede plantearse de forma inversa, es decir previa revisión de imágenes, plantear la posibilidad de acceder a determinados sitios, para identificar su composición florística y condición.

Es una realidad la utilización de los collares individuales para manejo del pastoreo bovino, denominados cercas virtuales, los cuales están registrando experiencias de implementación en Nueva Zelanda, Australia y Estados Unidos. Esta tecnología permite concentrar los animales en parcelas determinadas sin la necesidad de límites físicos (alambrados, boyeros), aumentando la carga instantánea logrando eliminar el pastoreo selectivo y mejorar la eficiencia de cosecha de pasto. Este aumento en la eficiencia de cosecha y rotación de las pasturas, permite a los productores incrementar la carga animal, disminuir costos operativos por armado de boyeros, arreo de animales, entre otras tareas. En un futuro no muy lejano la combinación de cercas virtuales y áreas homogéneas, nos permitirá hacer un pastoreo dirigido a determinados sectores, o poner presión sobre recursos puntuales, como en el caso de “El Bagual”, el olivillo, de forma que permita presionar específicamente sobre ellos, por lo que contar con estas áreas mapeadas, constituye un recurso fundamental para el armado de las parcelas virtuales. Finalmente, expresar que estas herramientas, si bien requieren para los técnicos de una formación que llevará cierto tiempo y esfuerzo, una vez alcanzada,

representan una manera sencilla y rápida de evaluación mucho más eficiente que cualquier método anterior.

7.BIBLIOGRAFÍA

Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. ISPRS Journal of Photogrammetry and Remote Sensing. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

Biurrun, F. N., Blanco, L. J., Oesterheld, M., & Paruelo, J. M. (2016). Spatial and temporal patterns of herbaceous primary production in semi-arid shrublands: a remote sensing approach. Journal of vegetation science, 27(4), 716-727.

Blanco, L., Quiroga, E., Luna Toledo, E., Sancho, A., Agüero, W., Molina, J., Biurrun, F., Díaz, R., Guzmán, L., Avila, R., & Ferrando, C. (2020). Manual para evaluación de pastizales naturales del Chaco Árido con fines ganaderos.

Borràs, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G., & Camps-Valls, G. (2017). Land use classification from Sentinel-2 imagery. Revista de Teledetección, 48, 55-66. <https://doi.org/10.4995/raet.2017.7133>

Breiman, L. (2001). Random Forests. Machine Learning, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>

Cabido, M. R., Zak, M. R., & Biurrun, F. (2018). La vegetación y el ambiente de la Provincia de La Rioja (Vol. 1). Universidad Nacional de Chilecito.

Cabrera, A. L. (1971). Fitogeografía de la república Argentina.

<https://naturalis.fcnym.unlp.edu.ar/bitstreams/ec1169b4-b937-4d0c-a87e-95c7eaedb1c1c/download>

Cesca, E. M., Villagra, P. E., & Álvarez, J. A. (2014). From forest to shrubland: Structural responses to different fire histories in *Prosopis flexuosa* woodland from the Central Monte (Argentina). *Journal of Arid Environments*, 110, 1-7.

Chaves, M. E. D., Picoli, M. C. A., & Sanches, I. D. (2020). Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, 12(18), 3062. <https://doi.org/10.3390/rs12183062>

Chuvieco, E. (1995). *Fundamentos de teledetección espacial* (2.^a ed.). Rialp.

Chuvieco, E. (2006). *Teledetección ambiental. La observación de la Tierra desde el Espacio*. Ariel.

Colditz, R. (2015). An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. *Remote Sensing*, 7(8), 9655-9679. <https://doi.org/10.3390/rs70809655>

Collado, A., & Echeverria, J. C. (2005). Variabilidad espacio temporal de los incendios rurales en las provincias de San Luis y Mendoza. EEA San Luis.

Congalton, R. (2001). Accuracy assessment and validation of remotely sensed and other spatial information. *International Journal of Wildland Fire*, 10, 321-328. <https://doi.org/10.1071/WF01031>

Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J.,

Wichmann, V., & Böhner, J. (2015). System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. Geoscientific Model Development, 8(7), 1991-2007. <https://doi.org/10.5194/gmd-8-1991-2015>

Corvalán, G., Mora, S., & Orozco, A. (2007). Olivillo (*Hyalis argentea* Don) como alternativa forrajera en periodos de bajos requerimientos de la vaca de cría en el sur de Mendoza. En IV Congreso Nacional Sobre Manejo de Pastizales Naturales. I Congreso del MERCOSUR Sobre Manejo de Pastizales Naturales.

Demaria, M. R., Martini, J. P., & Steinaker, D. F. (2016). Actualización del límite occidental del pastizal pampeano. Ecología Austral, 26(1). <https://doi.org/10.25260/ea.16.26.1.0.141>

Easdale, M. H., Umaña, F., Raffo, F., Fariña, C., & Bruzzone, O. (2019). Evaluación de pastizales patagónicos con imágenes de satélites y de vehículos aéreos no tripulados. Ecología Austral, 29(3), 306–314.

García-Consuegra Bleda, J. (1997). Problemática en la clasificación de imágenes de satélite Landsat. Revista de la Facultad de Educación de Albacete, (12), 319-330. <https://dialnet.unirioja.es/servlet/articulo?codigo=2291888>

Genbatu, G., Zhongjie, S., Yuanjun, Z., Xiaohui, Y., & Yuguang, H. (2020). Land use/cover classification in an arid desert-oasis mosaic landscape of China using remote sensed imagery: Performance assessment of four machine learning algorithms. Global Ecology and Conservation. <https://doi.org/10.1016/j.gecco.2020.e00971>

Golluscio, R. (2009). Receptividad ganadera: marco teórico y aplicaciones prácticas. Ecología Austral, 19(3), 215–232.

https://ojs.ecologiaaustral.com.ar/index.php/Ecologia_Austral/article/view/1334

Guevara, J. C., Cavagnaro, J. B., Estevez, O. R., Le Hou  rou, H. N., & Stasi, C. R. (1997). Productivity, management and development problems in the arid rangelands of the central Mendoza plains (Argentina). *Journal of Arid Environments*, 35(3), 337-348. <https://doi.org/10.1006/jare.1996.0194>

Guevara, J. C., Gr  nwaldt, E. G., Estevez, O. R., Bisigato, A. J., Blanco, L. J., Biurrun, F. N., & Passera, C. B. (2009). Range and livestock production in the Monte Desert, Argentina. *Journal of Arid Environments*, 73(2), 228-237

Guevara, J. C., Stasi, C. R., Wuilloud, C. F., & Estevez, O. R. (1999). Effects of fire on rangeland vegetation in south-western Mendoza plains (Argentina): composition, frequency, biomass, productivity and carrying capacity. *Journal of Arid Environments*, 41(1), 27-35.

Holechek, J. L. (1988). An approach for setting the stocking rate. *Rangelands*, 10(1), 10-14. <http://hdl.handle.net/10150/640265>

Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725–749.

K  chler, A. W. (1988). Vegetation mapping. En *General Geology* (pp. 853-855). Springer.

Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159-174. <https://doi.org/10.2307/2529310>

Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>

Mancino, G., Falciano, A., Console, R., & Trivigno, M. L. (2023). Comparison between Parametric and Non-Parametric Supervised Land Cover Classifications of Sentinel-2 MSI and Landsat-8 OLI Data. *Geographies*, 3(1), 82–109. <https://doi.org/10.3390/geographies3010005>

Matteucci, S., & Colma, A. (1982). Metodología para el estudio de la vegetación.

Matteucci, S., & Colma, A. (1998). El papel de la vegetación como indicadora del ambiente. En *Sistemas Ambientales Complejos: Herramientas de Análisis Espacial*.

Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(6), 1640-1691. <https://doi.org/10.1080/01431161.2018.1433343>

Mehmood, M., Shahzad, A., Zafar, B., Shabbir, A., & Ali, N. (2022). Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical Problems in Engineering*, 2022. <https://doi.org/10.1155/2022/5880959>

Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259.

Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222. <https://doi.org/10.1080/01431160412331269698>

Passera, C. B., Allegratti, L. I., & Robles, A. B. (2007). Effect of non-prescribed fire on an *Atriplex lampa* community, in the Guadal plateau of Mendoza province, Argentina. *Arid Land Research and Management*, 21(2), 91-105.

Perez, M., Bacaro, A., Del Barrio, L., Sosa, P., Suklje, M., Otta, S., Collado, R., D'Amario, J., Banchemo, S., De Abelleira, D., & Aloy, G. (2020). Clasificación de coberturas de suelo de la Cuenca del Río Tunuyán Superior.

Roig, F. A., Martínez Carretero, E., & Méndez, E. (2000). Mapa de vegetación de la Provincia de Mendoza. Recursos y Problemas Ambientales De Zona Árida.

Tacchini, F., Olmedo, G., Vallone, R., & Naldini, E. (2014). Ganadería Bovina de General Alvear.

Torre Azzaroni, M. L. (2022). Dinámica del paisaje de la reserva natural y Sitio Ramsar Villavicencio: (Mendoza, Argentina) durante el período 2000-2020 [Tesina de grado]. Universidad Nacional de Cuyo.

U.S. Geological Survey. (2022). Landsat—Earth observation satellites (Fact Sheet 2015–3081). <https://doi.org/10.3133/fs20153081>

S. Van den Bosch, J.C. Guevara, F.M. Tacchini, O.R. Estevez,(1997)Nutrient content of browse species in the arid rangelands of the Mendoza plain, Argentina,*Journal of Arid Environments*.<https://doi.org/10.1006/jare.1997.0285>

Wulder, M. A., Coops, N. C., Roy, D. P., White, J. C., & Hermosilla, T. (2018). Land Cover 2.0. *International Journal of Remote Sensing*, 39(14), 4254–4284.