

# MAP BIOMAS

## AMAZONÍA

Apéndice - Coberturas Pastos (Pastura)

Tema transversal en Colección 6.0

Versión 1

Equipo responsable

Sara Espinoza

Rodney Camargo

Septiembre 2024

<b>Índice</b>	
<b>1. Introducción</b>	<b>3</b>
<b>2. Metodología</b>	<b>4</b>
<b>2.1. Definición de la clase Pasto (ID 15)</b>	<b>4</b>
<b>2.1. Búsqueda de datos</b>	<b>4</b>
<b>2.2. Preparación de los datos</b>	<b>6</b>
<b>2.3. Muestras de Pastos/no Pastos</b>	<b>7</b>
<b>2.4. Estrategias complementarias previas a la clasificación</b>	<b>8</b>
<b>2.5. Resumen metodológico</b>	<b>10</b>
<b>3. Mosaicos de imágenes</b>	<b>11</b>
<b>3.1. Preprocesamiento de imágenes</b>	<b>11</b>
<b>3.2. Definición del periodo de imágenes</b>	<b>11</b>
<b>4. Clasificación</b>	<b>11</b>
<b>4.1. Variables de clasificación</b>	<b>12</b>
<b>5. Post-clasificación</b>	<b>15</b>
<b>5.1 Filtro temporal</b>	<b>16</b>
<b>5.2 Filtro espacial</b>	<b>16</b>
<b>5.3 Filtro de frecuencia</b>	<b>17</b>
<b>Recomendaciones</b>	<b>18</b>
<b>Consideraciones</b>	<b>19</b>
<b>Referencias</b>	<b>20</b>

## 1. Introducción

A medida que crece la población mundial y los ingresos, la demanda general de alimentos aumentará en un 60% a mediados de siglo y la demanda de alimentos de origen animal en casi un 50%. Actualmente, el 44% de las exportaciones mundiales de carne de res y el 42% de aves de corral provienen de América Latina y el Caribe (FAO, 2021), formando parte del conjunto de productos que sitúan a la región como el mayor exportador neto de alimentos del mundo.

La ganadería bovina en América Latina presenta problemas de baja productividad y un uso poco eficiente de los recursos, generando una serie de impactos ambientales negativos sobre los bosques, el suelo y la biodiversidad, factores como el continuo crecimiento poblacional, acelerados procesos de urbanización y el aumento de capacidad adquisitiva indican que la demanda de proteína animal será mayor en los próximos años.

El estudio de la dinámica de ocupación de la tierra por pastos durante 38 años en el territorio es un reto, inicialmente son realizados por ganadería tradicional, es decir ganadería utilizando los pastos naturales o uso extensivo, posteriormente se hace uso de tecnología, y es precisamente por este motivo, que para ser mapeados tiene como necesario contar con datos históricos, especialmente para reducir la confusión que existe con otros usos de suelos (agricultura, áreas sin vegetación, urbano, sabanas).

Frente a esta realidad, y el hecho de que la ganadería incrementará, surge el reto de mapear, debido a que los países presentan diferencias importantes en el contexto sociocultural, condiciones climáticas y prácticas de manejo implementadas en sus sistemas ganaderos; así como la adecuada comprensión de la problemática local y sus potenciales soluciones, constituyen el paso base para desarrollar esquemas de construcción de capacidades para comprender esta dinámica, creando las condiciones para implementar nuevas tecnologías y prácticas de manejo que permita mejorar la identificación pastos cultivados y áreas con ganadería.

Se estima que aproximadamente el 70% de la superficie destinada a pastizales en América Latina y el Caribe sufre procesos de degradación. La compactación y erosión del suelo forman parte de los problemas relacionados con la disminución de la calidad de las pasturas, afectando también la productividad en los sistemas ganaderos que dependen de este recurso como principal fuente de alimento para los animales. Además del impacto en productividad, los procesos de degradación también contribuyen a la ampliación de la frontera pecuaria, al buscar nuevas áreas que posean condiciones favorables para el establecimiento de pastizales.

En este contexto, implementar enfoques que permitan la adecuada gestión del paisaje agropecuario y la recuperación del suelo cobran especial relevancia, y el monitoreo de esta actividad permite implementar estas iniciativas en zonas que lo necesiten.

La identificación y mapeo de la actividad ganadera mediante el uso de información satelital georreferenciada y las herramientas digitales facilitan el acceso a datos en tiempo real para la toma de decisión. Los mapas generados del cambio de uso del suelo permiten comprender el estado del suelo, monitorear sus condiciones y la evolución de las áreas degradadas o desertificadas. Esta información permite orientar a tomadores de decisión que, al cruzar estos datos con información climática y socioeconómica podrán obtener mejores resultados sobre esta actividad.

## **2. Metodología**

Para generar la clasificación de pastos (áreas de pastoreo o zonas ganaderas), se desarrolló una ruta de proceso formada por cuatro etapas (scripts) que permitieron separar áreas de pastos y no pastos a partir de mosaicos Landsat previamente definidos y almacenados en Google Earth Engine. Estas etapas del proceso involucran la identificación de las áreas de pastos y su clasificación.

El detalle de información requerido suele percibirse como una potencial barrera para implementar la identificación de zonas con pastura, por ello es de gran importancia adaptar las herramientas para recolección de datos y realizar procesos de fortalecimiento de capacidades con personal técnico y productores; además de empresas o instituciones del rubro con datos de campo que permitan calibrar a la hora de realizar la clasificación.

### **2.1. Definición de la clase Pasto (ID 15)**

Esta clase de cobertura está definida como áreas donde la cobertura original ha sido modificada o reemplazada por pastos (plantas gramíneas y leguminosas) que se desarrollan en campo y sirven para fines pecuarios. Área de pastos, predominantemente plantadas, vinculadas a actividad agropecuaria. Las áreas de pastos naturales son predominantemente clasificados como formación campestre que pueden o no ser utilizadas para pasturas.

### **2.1. Búsqueda de datos**

En esta etapa se realizó una búsqueda de fuentes de datos (mapas, reportes, informes), con el objetivo de localizar las principales áreas donde se realiza la actividad pecuaria. Los países que mapearon pastos son: Bolivia, Ecuador, Colombia, Perú y Venezuela. A continuación, se describe cada paso (ver figura 1).




Figura 1: Mapa con los países donde se mapeo la clase Pastos Colección 6.0

Con la base datos recopilada por cada país se procedió a añadir el dato **tiempo**, basado en la fecha que se tenía de cada muestra y así obtener el inicio de esta actividad en el territorio, tomando como base los mosaicos Landsat, y así adquirir en lo posible la temporalidad, necesario para clasificar año a año. Con ello se generó una capa de puntos con datos de pastos y no pastos, utilizando una herramienta de Sistemas de Información Geográfica (SIG) para su visualización espacial como mapas de puntos (ver figura 2).




Figura 2: Puntos de colecta de clase Pastos (ID 15) Colección 6.0



Figura 3. Amazonía Baja Este – San Ignacio de Velasco. Fuente FEGASACRUZ

## 2.2. Preparación de los datos

El mapa de puntos generado se importó a Google Earth Engine, para su visualización. El mapa de puntos ingresa como **input de datos** de la presencia de pastos y no pastos (mapa de fondo), también se utilizaron las imágenes de alta resolución espacial de Google Maps para generar la colección 6.0 de MapBiomás Amazonia para incorporar puntos adicionales para optimizar las muestras (ve figura 3).

Usando estos datos se generó una capa de polígonos envolventes alrededor de la nube de puntos como **Área de Interés - AOI** (figura 2) para cada región, cabe señalar que se utilizó información de puntos de zonas de agricultura que se clasificaron como **no pastos**.



Figura 4: Puntos de muestras de Pasto y no-Pasto

### 2.3. Muestras de pasto/no pasto

Los polígonos representan las áreas donde identificar las clases a ser clasificadas dentro de las imágenes. En cada polígono se deben generar una capa de puntos de entrenamiento en donde se definan pasto como de no pasto (figura 4, 5, 6 y 7).




Figura 5: Áreas de entrenamiento asignadas para a inspección visual e identificar Pasto y no-Pasto




Figura 6: Áreas de entrenamiento con las clases consolidadas de Pasto y no-Pasto. En círculo las áreas detectadas como pasto.



*Figura 7: Actividad ganadera en Santiago de Moxos en la llanura de inundación – Bolivia*

Un paso que apoyó en la clasificación fue identificar la importancia relativa de variables, la cual presenta los predictores en el orden de su efecto en la mejora del modelo de clasificación para el transversal pasto, si bien el método tiene la posibilidad de incluir un gran número de variables *input* este paso permite *identificar* la variable con la puntuación de mejora más alta e importante, y las otras variables siguen en orden de importancia. Entonces, importancia relativa se define como la mejora porcentual con respecto al predictor más importante, donde los valores de importancia relativa de variables oscilan entre 0% y 100%. (ver figura 8)



## Flujograma Metodológico - Importancia de Variables

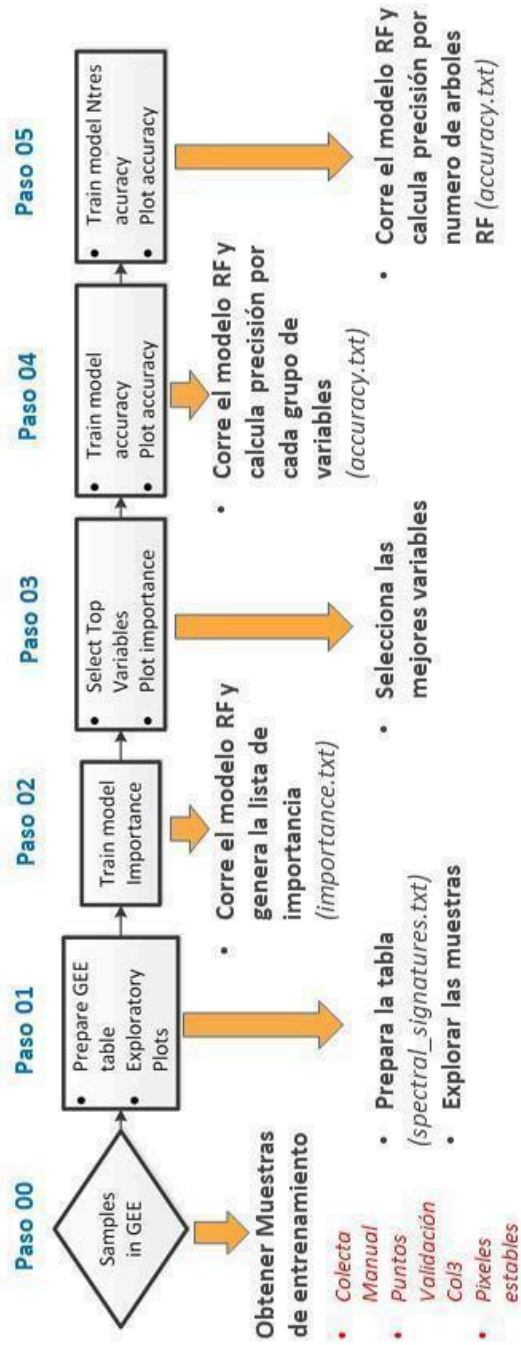


Figura 8: Importancia de variables – Clase Pasto (ID: 15)

## 2.4. Estrategias complementarias previas a la clasificación

La pastura forrajera perenne es una especie que requiere siembra y tiene una duración de 4, 5 o más años, manteniendo el suelo cubierto todo el año. No obstante, es necesario realizar cortes aproximadamente cada 60 días, dependiendo del tipo de pastura. Debido a este comportamiento se logró una mejor precisión utilizando la transversal de agricultura en comparación a la transversal de pastos para algunas regiones donde la dinámica de estas clases era similar (figura 9).



Figura 9: Resultado de la clasificación de clase Agricultura (ID 18 - color rosado) y Pasto (ID 15 - color naranja)

Los valores de la reflectancia y los índices de vegetación que presentan las pasturas son similares a la de algunos cultivos, como, por ejemplo, el del trigo en sus primeras fases de desarrollo. Por esta razón empleando la transversal de agricultura, el clasificador logró separar los píxeles de esta cobertura. Sin embargo, la detección no es de las más precisas, es por eso por lo que se deben realizar ajustes principalmente de temporalidad en los mosaicos y en el trabajo de campo para mejorar la detección de pasturas (ver figura 10).



Figura 10: Pasturas en San Javier (Santa Cruz - Bolivia), Landsat (swir,nir,red). Clasificación de pastos con transversal de agricultura

## 2.5. Resumen metodológico

En este documento, presentamos una descripción de la metodología aplicada para el mapeo de pasto, el proceso completo se dividió en 4 etapas. (ver figura 11)

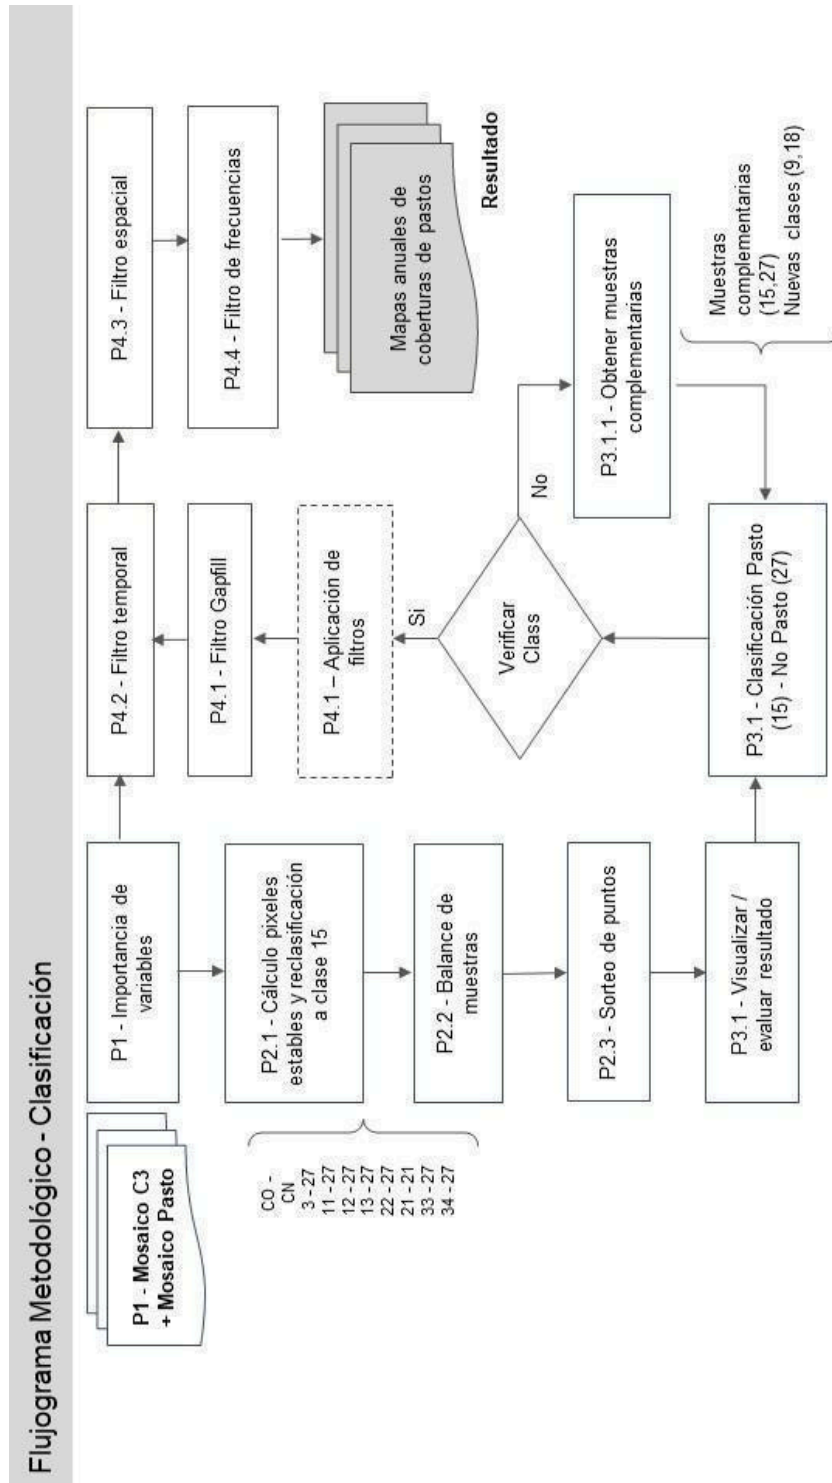


Figura 11: Pasos para la clasificación de Pastos

### **3. Mosaicos de imágenes**

La clasificación del tema transversal “Pastos” utilizó los mosaicos de imágenes Landsat generados para el mapa general de la Colección 6.0 MapBiomias Amazonía.

#### **3.1. Preprocesamiento de imágenes**

El conjunto de datos Landsat 5 se obtuvo a partir de las imágenes de reflectancia superficial corregidas atmosféricamente del sensor Landsat 5 ETM, el conjunto de datos Landsat 7 a partir de imágenes de reflectancia de superficie con corrección atmosférica del sensor Landsat 7 ETM +, Landsat 8 se obtuvo a partir de un conjunto de imágenes de reflectancia de superficie con corrección atmosférica de los sensores OLI / TIRS de Landsat 8 y Landsat 9 se obtuvo a partir de un conjunto de imágenes de reflectancia de superficie con corrección atmosférica de los sensores OLI / TIRS de Landsat 9. Lo anterior, a una resolución espacial de 30 metros.

#### **3.2. Definición del periodo de imágenes**

La serie de tiempo se normalizó a valores de reflectancia de la parte superior de la atmósfera (TOA) y filtrados con banda de evaluación de calidad, cuyo objetivo es eliminar los valores de píxeles contaminados por nubes y / o sombras de nubes (Roy et al., 2014).

Apuntando a un mayor número de observaciones disponible para este proceso, la ventana de tiempo elegida fue de 24 meses, para garantizar la prevalencia de observaciones de buena calidad para un año específico (por ejemplo, el espacio de características 2015 consideró imágenes del último semestre de 2014 y primer semestre de 2016).

### **4. Clasificación**


La clasificación automática de los mosaicos Landsat se realizó íntegramente en la plataforma Google Earth Engine, basada en el clasificador Random Forest (Breiman, 2001). El proceso de clasificación se realizó siempre considerando sólo dos clases posibles para cada píxel, Pasto (clase de interés) y la clase no-Pasto (todo lo diferente a la clase de interés).

Para la clasificación supervisada de los mosaicos Landsat, se utilizaron muestras de entrenamiento basadas en puntos de actividad pecuaria, apoyado de la herramienta de inspección visual temporal y los mosaicos de la colección 6.0 de MapBiomias Amazonía (ver figura 12, círculo negro), que permite la recuperación de Landsat imágenes, a través de Google Earth Engine (Nogueira et al., 2017), y la determinación, para todos los puntos, a lo largo de los 38 años considerados en este estudio, de la

respectiva clase de cobertura / uso de la tierra y eventuales cambios.

Considerando que las áreas de pastos son muy susceptibles a variaciones climáticas interanuales (Ferreira et al., 2013) y presentan diferentes características biofísicas y de manejo (Aguiar et al., 2017; Ferreira et al., 2013b), se realizó ajuste a la metodología para que pueda ser empleada en el territorio de análisis, este enfoque permitió al modelo de clasificación una mejor identificación. Sin embargo, para minimizar el impacto de la estratificación geográfica, parte de las muestras de entrenamiento se compartió entre diferentes modelos de clasificación y se utilizó información de importancia de variables que agilizo el resultado y ajusto al territorio según la región donde se aplicó el script.

La heterogeneidad del territorio, y el hecho de que esta actividad se encuentra realizada muchas veces en comunión con la agricultura se vio la necesidad de mapear ambas clases en la Transversal Agricultura, donde se obtuvieron resultados que fueron evaluados por cada país y posteriormente comparados con los resultados de Transversal Pastos, si bien para algunas regiones los resultados obtenidos reflejaron el desarrollo de esta actividad, en algunas zonas se evidencio confusión entre ambas clases.



*Figura 12: Imágenes Landsat vs área utilizada para Pastura*

#### **4.1. Variables de clasificación**

En los valores de píxeles resultantes, se aplicaron cinco operaciones (media, desviación estándar, mínimo, máximo y amplitud) en seis bandas espectrales (verde, rojo, infrarrojo cercano, infrarrojo de onda corta 1 e infrarrojo de onda corta 2) y tres índices espectrales: NDVI (Normalizado Índice de Vegetación de Diferencia, Huete et al., 1997), NDWI (Normalizado Diferencia del Índice de Agua, Gao, 1996) y CAI (Absorción de celulosa Index, Nagler et al., 2003). Ver Tabla 1, Tabla 2 y Tabla 3.

Índice	Wet min	Wet max	Wet median	Wet amp	Wet stdDev
green	x	x	x	x	x
red	x	x	x	x	x
nir	x	x	x	x	x
swir1	x	x	x	x	x
swir2	x	x	x	x	x
ndvi	x	x	x	x	x
ndwi	x	x	x	x	x
cai	x	x	x	x	x

*Tabla 1. Cinco operaciones utilizadas: media, desviación estándar, mínimo, máximo y amplitud*

Se aplicó análisis de percentiles en seis bandas espectrales (verde, rojo, infrarrojo cercano, infrarrojo de onda corta 1 e infrarrojo de onda corta 2) y tres índices espectrales: NDVI (Normalizado Índice de Vegetación de Diferencia). (ver figura 13)

Índice	Wet p10	Wet p25	Wet p75	Wet p90
green	x	x	x	x
red	x	x	x	x
nir	x	x	x	x
swir1	x	x	x	x
swir2	x	x	x	x
ndvi	x	x	x	x
ndwi	x	x	x	x
cai	x	x	x	x

*Tabla 2. Análisis de percentiles en seis bandas y tres índices espectrales*

Índice	dato
elevación	x
pendiente	x
longitud	x
latitud	x

Tabla 3. Índices de apoyo




Figura 13: Clase Pasto identificado en la imagen satelital y su clasificación.

**Nota**

Incluir una cantidad considerable de puntos de muestras puede generar errores de uso de memoria excedida.

## 5. Post-clasificación

Para homogeneizar mejor los resultados, se aplicó los filtros: espacial, temporal y frecuencia, capaz de minimizar abruptos y a veces variaciones irreales, considerando simultáneamente estas las dimensiones espacio y tiempo.

### 5.1 Filtro temporal

El filtro temporal utiliza clasificaciones secuenciales en una ventana móvil unidireccional de 3, 4 o 5 años para identificar transiciones temporalmente incoherentes. Basado en una sola regla genérica (RG), el filtro temporal inspecciona la posición central de los años consecutivos, y si los extremos del análisis son idénticos pero la posición central no lo es, entonces el píxel central se reclasifica hacia la clase del vecino temporal. (ver figura 14)

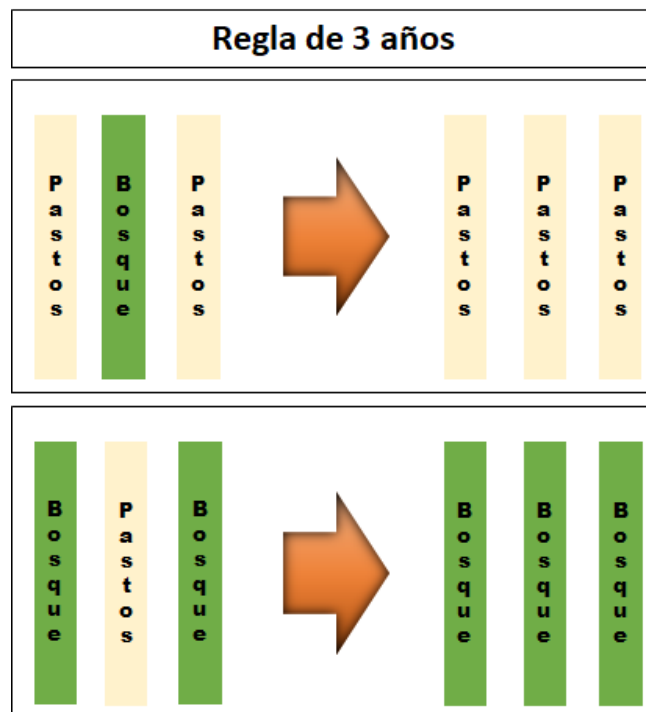


Figura 14: Efecto de la aplicación del filtro temporal

### 5.2 Filtro espacial

A continuación, se aplica un filtro espacial basado en la función "connectedPixelCount", que identifica al conjunto de píxeles (vecindario) que comparten un mismo valor de píxel. En consecuencia, sólo los píxeles que no presentan conexión considerando una cantidad mínima predefinida de píxeles idénticos son definidos como píxeles aislados y reclasificados. (ver figura 15)






Figura 15: Efecto de la aplicación del filtro espacial

### 5.3 Filtro de frecuencia

El último filtro, frecuencia, considera la ocurrencia de la clase a lo largo de la serie temporal para limpiar el resultado de la clasificación. (ver figura 16)




Figura 16: Efecto de la aplicación del filtro frecuencia

Luego de la aplicación de la secuencia de filtros en la etapa de post clasificación, los temas transversales y los mapas generales de cada bioma son integrados. Esta integración depende de una serie de reglas jerárquicas específicas que asignan un orden de prevalencia a cada clase (Tabla 4). Como resultado de esta etapa se obtienen los mapas anuales de cobertura y uso de la tierra, con la clase Pastos. (ver figura 17)




Figura 17: Mosaico de la clase Pastos (ID 15), año 2021. Colección 6

## Recomendaciones

Se recomienda que el trabajo de teledetección de pastos debe ser apoyado con datos de entrenamiento o de campo para definir un modelo de la respuesta espectral que se aproxime al cultivo. Sin embargo, es necesario contar con información multispectral tomada en el campo y en el laboratorio, que permita estimar en mejor medida las características biofísicas del cultivo, ajustando los parámetros de reflectancia para una correcta interpretación. (ver figura 18)




Figura 18: Serie Landsat de NDVI para la clase Pastos (ID 15)

## Consideraciones

La especial dinámica de estas áreas parece estar correctamente capturada, debido a que los pastos se caracterizan generalmente como el primer uso de la tierra, generalmente avanzando sobre áreas de vegetación natural (Cardille y Foley, 2003; Barona et al., 2010), en especial en la de sabanas o formación campestre, donde el uso de suelo cedió espacio para una mayor economía de cultivos agrícolas rentables, como la soja y la caña de azúcar (Sparovek et al., 2009; Scheffler et al., 2011) y posteriormente pastos cultivados.

El mapeo de pastos elaborado para este estudio presenta errores de omisión debido a la falta de información base, para los años iniciales principalmente. Se sugiere que el mapeo de puntos de muestras debe ser analizado para aumentar la certeza de las áreas identificadas para esta clase; se reportó poca información referencial y dificultad de encontrar muestras estables.

De hecho, dada la dificultad de establecer criterios explícitos para la identificación de los pastos, a menudo relacionados con prácticas antrópicas y no capturados completamente por datos de teledetección, presentaron problemas a la hora de identificar formaciones naturales no forestales – pastos naturales o sabanas que están presentes en la región de mapeo.

El uso de nuevas herramientas que puedan medir la intensidad y/o la frecuencia de los extremos climáticos, como sequías y olas de calor, pueden generar resultados en los cambios sostenidos en la función de los ecosistemas con importantes impactos ecológicos y económicos para los pastizales y pastos manejados. El experimento Pastures and Climate Extremes (PACE) en el sureste de Australia fue diseñado para investigar los impactos de una severa sequía de invierno/primavera, una combinación factorial de sequía y aumento temperatura sobre la productividad del pasto, que expone a zonas de pastos a extremos climáticos y su impacto; ejemplos como este podrían apoyar en el conocimiento del comportamiento de esta clase en las regiones de mapeo.

## Referencias

Andrade, Ricardo; Bolfe, Édson; Victoria, Daniel; Nogueira, Sandra (2017). Avaliação das condições de pastagens no cerrado brasileiro por meio de geotecnologias. Revista Brasileira de Agropecuária Sustentável

CUMAT. (2001). Mapa de capacidad de uso mayor de la tierra Bolivia. Geobolivia. Recuperado de: <https://geo.gob.bo>

Churchill AC, Zhang H, Fuller KJ, Amiji B, Anderson IC, Barton CVM, Carrillo Y, Catunda KLM, Chandregowda MH, Igwenagu C, Jacob V, Kim GW, Macdonald CA, Medlyn BE, Moore BD, Pendall E, Plett JM, Post AK, Powell JR, Tissue DT, Tjoelker MG and Power SA (2022) Pastures and Climate Extremes: Impacts of Cool Season Warming and Drought on the Productivity of Key Pasture Species in a Field Experiment.

FAO. (1978). Mapa de cobertura y uso de la tierra,1978. Geobolivia. Recuperado de: <https://geo.gob.bo>

Ibisch,P., Beck, S.,Gerkmann, B., Carretero, A., 2003. *Ecoregiones y ecosistemas*. Editorial Fundación Amigos de la Naturaleza. Santa Cruz-Bolivia

Ministerio de Desarrollo Productivo y Economía Plural (2009). Unidad de Análisis Productivo, Subsistema de Información Territorial de Apoyo a la Producción. Atlas de potencialidades productivas del Estado Plurinacional de Bolivia. La Paz-Bolivia

Navarro, G. 2002. Vegetación y unidades biogeográficas de Bolivia. Centro de Ecología y Difusión Simón I. Patiño (eds). Cochabamba-Bolivia

Navarro, G. 2011. Clasificación de la vegetación de Bolivia. Centro de Ecología y Difusión Simón I. Patiño (eds). Santa Cruz-Bolivia

Opio, C. y Sangoluisa Rodriguez, P. 2022. Innovaciones en el sector ganadero - Compendio de experiencias en América Latina y el Caribe 2021. Panamá, FAO e IICA.

Perspectivas de la Agricultura y del Desarrollo Rural en las Américas: una mirada hacia América Latina y el Caribe 2021-2022 / CEPAL, FAO e IICA. – San José, C.R.: IICA, 2021

Superintendencia Agraria (2001). Mapa de cobertura y uso actual de la tierra Bolivia, 2001. Recuperado de: <https://geo.gob.bo>

UDAPRO & SITAP (2013). Mapa de Potenciales Productivas de Bolivia. Geobolivia. Recuperado de: <https://geo.gob.bo>

UTNIT (2010). Mapa de cobertura y uso actual de la tierra Bolivia. Geobolivia. Recuperado de: <https://geo.gob.bo>

ZAE. (2002). Mapa de zonificación agroecológica de Bolivia. Geobolivia. Recuperado de: <https://geo.gob.bo>