



## Parte 2: Mapeo de la Extensión de Manglares y Series Temporales

Abigail Barenblitt y Lemilola Fatoyinbo

12 de noviembre de 2020





# Estructura y Material del Curso

- Tres sesiones de una hora media cada una el 5, 12 y 19 de noviembre
- Se presentará el contenido en el siguiente horario:  
11h a 12h Horario Este de EE.UU.  
(UTC-5) (English)



# Estructura y Material del Curso

- Las grabaciones de las presentaciones, los archivos PowerPoint y la tarea asignada se pueden encontrar después de cada sesión en:
  - <https://appliedsciences.nasa.gov/join-mission/training/english/remote-sensing-mangroves-support-un-sustainable-development-goals>
  - Preguntas y Respuestas después de cada presentación y/o por correo electrónico a:
    - [lola.fatoyinbo@nasa.gov](mailto:lola.fatoyinbo@nasa.gov) o
    - [abigail.barenblitt@nasa.gov](mailto:abigail.barenblitt@nasa.gov)



# Tarea y Certificados

- **Tarea:**

- Se asignará una tarea después de cada sesión
- Debe enviar sus respuestas vía Google Forms
- **Fecha límite de entrega para la tarea no. 2: jueves 26 de noviembre**

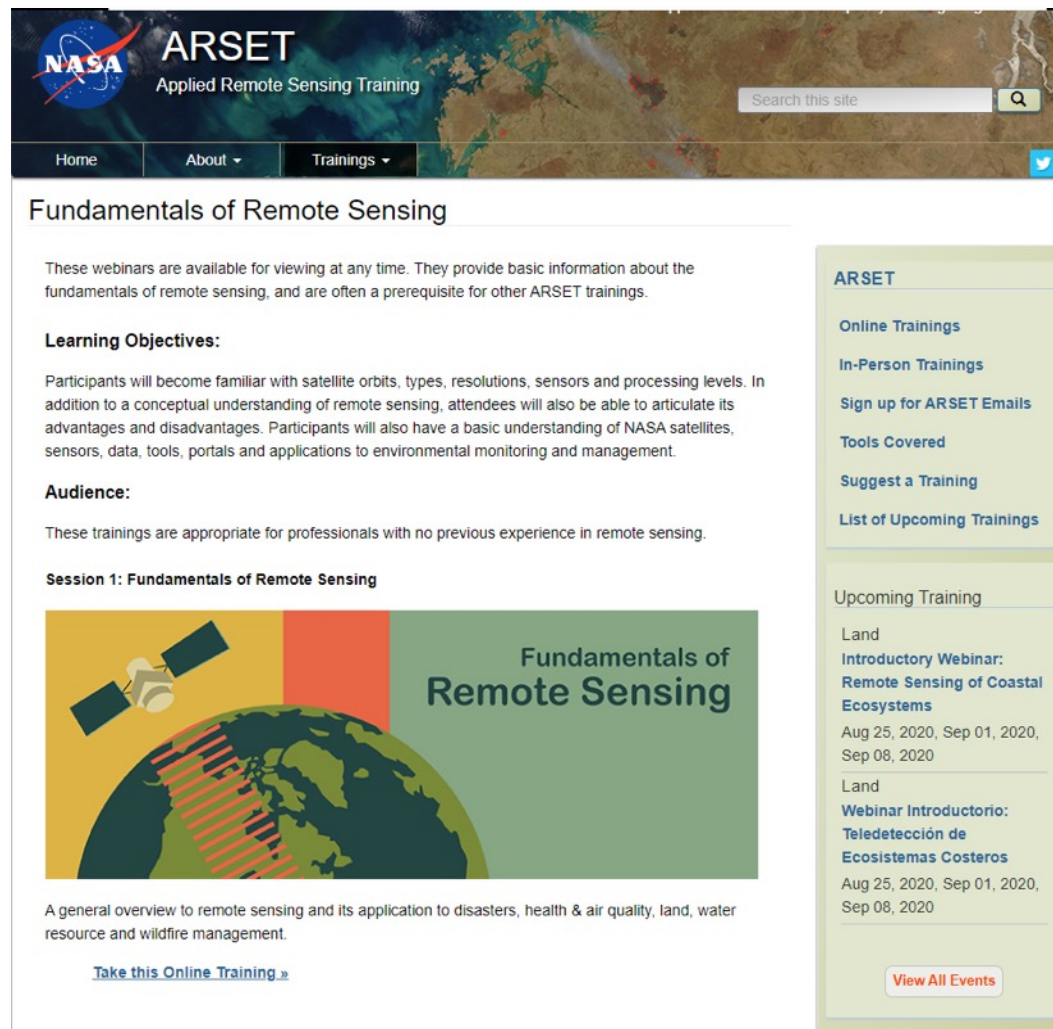
- **Certificado de Finalización de Curso:**

- Asista a las tres sesiones en vivo
- Complete las tareas asignadas en el plazo estipulado (acceso desde la página web de ARSET)
- Recibirá su certificado aproximadamente dos meses después de la conclusión del curso de [marines.martins@ssaihq.com](mailto:marines.martins@ssaihq.com)



# Prerrequisitos

- Versión Requerida de QGIS: 3.10-  
<https://www.qgis.org/en/site/forusers/download.html>
  - Descargar e Instalar el Plugin Class Accuracy para QGIS-  
<https://github.com/remotesensinginfo/classaccuracy>
  - Para instrucciones sobre la instalación le referimos a este video-  
<https://www.youtube.com/watch?v=NJRdKpmujRo>
  - [Fundamentos de la Percepción Remota \(Teledetección\)](#)
  - [Intro to JavaScript for GEE](#)
  - Crear una cuenta de Google Earth Engine
- Opcional:
- [GEE Beginner's Cookbook](#)
  - [GEE Managing Assets](#)
  - [Introduction to Google Earth Engine Tutorial](#)



The screenshot shows the NASA ARSET (Applied Remote Sensing Training) website. The header includes the NASA logo, the text 'ARSET Applied Remote Sensing Training', and a search bar. The main content area is titled 'Fundamentals of Remote Sensing' and contains the following text:

These webinars are available for viewing at any time. They provide basic information about the fundamentals of remote sensing, and are often a prerequisite for other ARSET trainings.

**Learning Objectives:**

Participants will become familiar with satellite orbits, types, resolutions, sensors and processing levels. In addition to a conceptual understanding of remote sensing, attendees will also be able to articulate its advantages and disadvantages. Participants will also have a basic understanding of NASA satellites, sensors, data, tools, portals and applications to environmental monitoring and management.

**Audience:**

These trainings are appropriate for professionals with no previous experience in remote sensing.

**Session 1: Fundamentals of Remote Sensing**

The session is illustrated with a graphic showing a satellite orbiting Earth, with the text 'Fundamentals of Remote Sensing' overlaid. Below the graphic, it states: 'A general overview to remote sensing and its application to disasters, health & air quality, land, water resource and wildfire management.' A button labeled 'Take this Online Training »' is provided.

On the right side of the page, there is a sidebar with the following sections:

- ARSET**
  - Online Trainings
  - In-Person Trainings
  - Sign up for ARSET Emails
  - Tools Covered
  - Suggest a Training
  - List of Upcoming Trainings
- Upcoming Training**
  - Land
    - Introductory Webinar: Remote Sensing of Coastal Ecosystems
      - Aug 25, 2020, Sep 01, 2020, Sep 08, 2020
    - Land
      - Webinar Introductorio: Teledetección de Ecosistemas Costeros
        - Aug 25, 2020, Sep 01, 2020, Sep 08, 2020
  - [View All Events](#)



# Objetivos de Aprendizaje

Al final de esta presentación, usted podrá:

- Entender cómo utilizar Google Earth Engine a un nivel básico
- Crear un mapa de la extensión de manglares utilizando una clasificación “Random Forest”
- Crear una serie temporal para cambios en la extensión de los manglares



# Esquema

- 1) Repaso de Google Earth Engine (GEE)
- 2) Repaso del Análisis de Series Temporales
- 3) Demostración del Análisis de Series Temporales para Guyana
  - Configuración del Mapa
  - Filtrado de una imagen Landsat Compuesta
  - Construcción de un Modelo “Random Forest”
  - Comparación de Series Temporales
  - New Random Forest
  - Cálculo de la Superficie de Manglares
  - Exportación de Áreas de Interés
  - Demostración del Plug-in QGIS Class Accuracy





# ¿Qué es Google Earth Engine?


- Una “plataforma de procesamiento geoespacial basada en la nube” libre y de fuente abierta
- Comprende:
  - Un catálogo de conjuntos de datos disponibles al público
  - El poder computacional de Google
  - Una interfaz de programación de aplicaciones (Application Programming Interface o API)
  - Un editor de código

La misión de Google:

Nuestra misión es **organizar** la **información** del mundo y hacer que sea **útil** y **accesible para todos**.



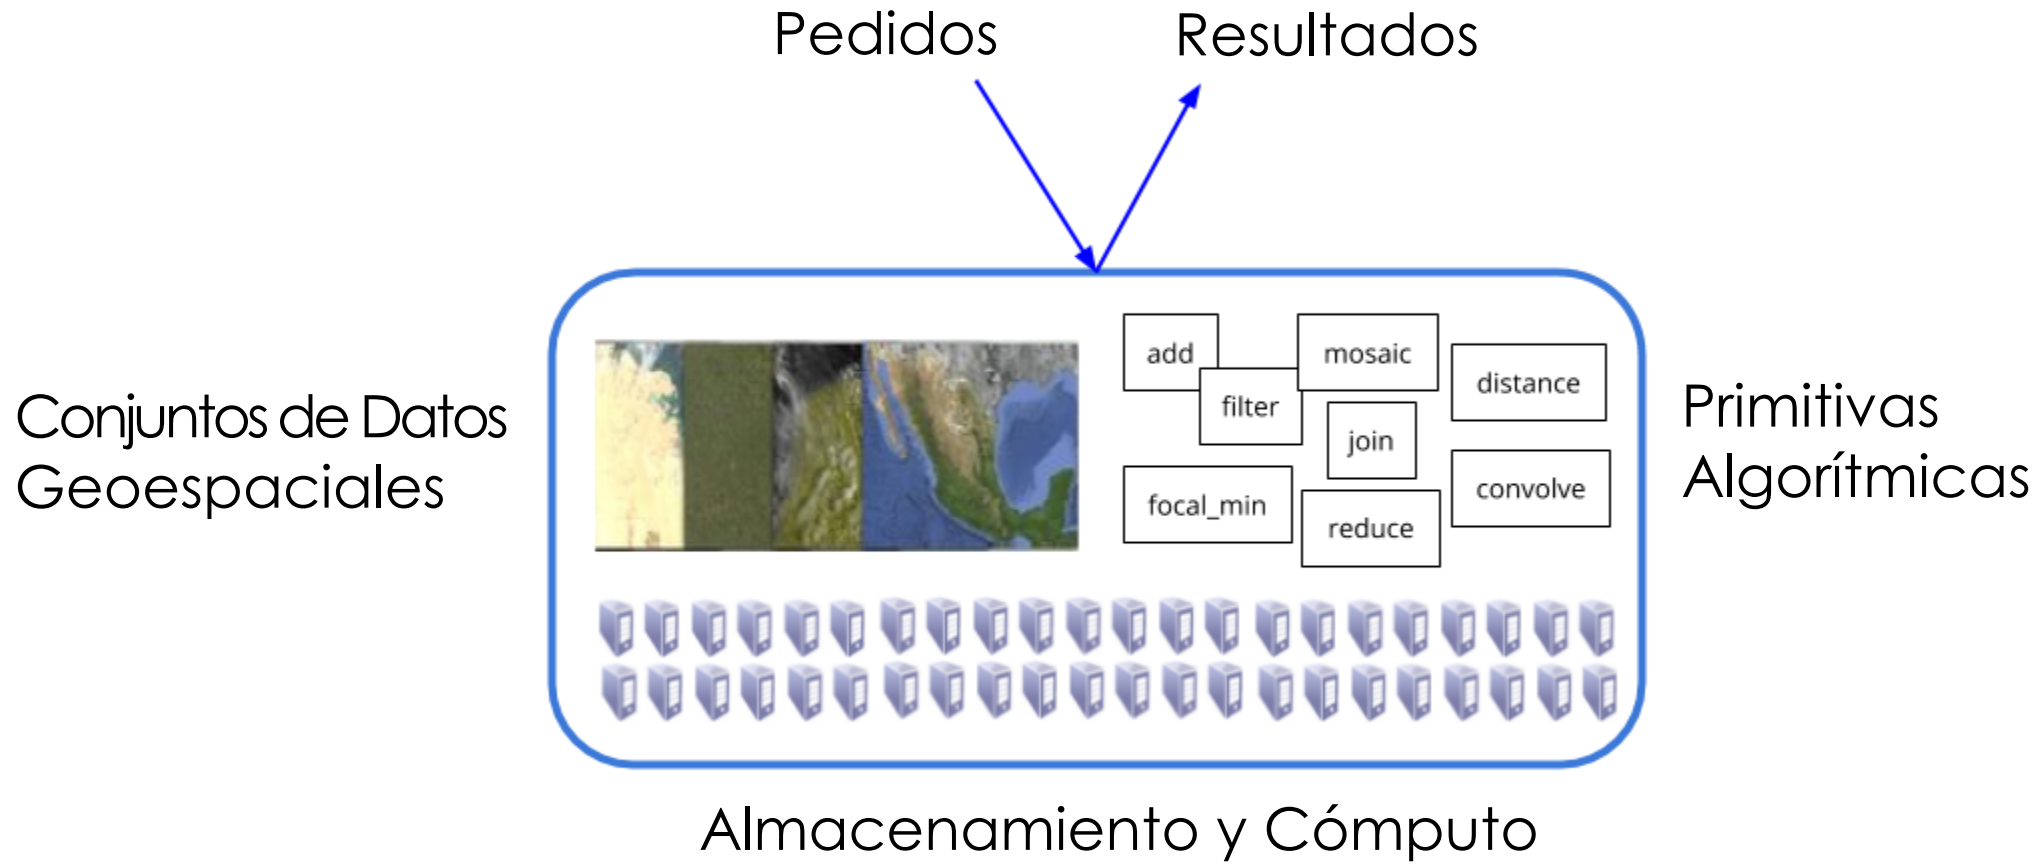




# Cómo Funciona GEE

- En la nube
  - Funciones de cliente vs. funciones de servidor
  - Los usuarios manipulan objetos “proxy” a través del servidor
  - Se envían las instrucciones a Google para su procesamiento y los resultados los envían de vuelta al navegador web para su visualización
- Preconfigurado con Proyecciones WGS84
- Capacidades/Limitaciones
  - Escala planetaria
  - Hay restricciones de cuotas debido a que es de fuente abierta
  - Hay memoria limitada para cada usuario





# El Editor de Código

- Para análisis más detallados
- Editor de código JavaScript (Python disponible)
- Visualización de mapas
- Documentación de referencia API (Pestaña “Docs”)
- Salida de consola (Pestaña “Console”)
- Administrador de tareas (Pestaña “Tasks”)
- Búsqueda de mapas interactiva (Pestaña “Inspector”)





# Glosario de Términos

- **Google Earth Engine Asset**

- Conjunto de datos externos cargado a Google Earth Engine para el análisis

- **Table**

- Datos vectoriales en formato shapefile
- Ejemplo: Datos de ubicaciones verificados con datos en el suelo

- **Image**

- Datos ráster compuestos de una o más bandas
- Ejemplo: Distancia euclidiana

- **Image Collection**

- Una pila o serie temporal de imágenes
- Ejemplo: Imágenes de Landsat 8



Scripts Docs Assets

- ▶ users/acbarenblitt/javapractice
- ▼ users/acbarenblitt/Mangroves
  - ▶ Modules
  - ▣ Global Heights V3
  - ▣ Global Heights V4
  - ▣ Global Heights v2
  - ▣ Goldmining
  - ▣ LandTrendrNigeria
  - ▣ MangroveCompare(FullCode)
  - ▣ MangroveComparisonNathan
  - ▣ MangroveNatFull
  - ▣ MangrovesCompare(BelizeRast...
  - ▣ MangrovesGUITest
  - ▣ NigeriaLola
  - ▣ RaiNExample

NigeriaLola

Get Link Save Run Reset


```

41   var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0).and(qa.bitwiseAnd(cloudsBitMask).eq(0)); // Both flags should
42   return image.updateMask(mask).divide(10000).copyProperties(image, ["system:time_start"]); // Return the masked image,
43 }
44
45 // This function can then be mapped in both Landsat 7 and 8 Collections
46
47 // 2.2 SPECTRAL INDICES
48
49 // Both collections have different band numbers that are different, so I created two functions in regard to each indiv
50
51 // This function maps spectral indices for Mangrove Mapping using Landsat 7 Imagery
52 var addIndicesL7 = function(img) {
53   // NDVI
54   var ndvi = img.normalizedDifference(['B4','B3']).rename('NDVI');
55   // NDMI (Normalized Difference Mangrove Index - Shi et al 2016 - New spectral metrics for mangrove forest identifica
56   var ndmi = img.normalizedDifference(['B7','B2']).rename('NDMI');
57   // MNDWI (Modified Normalized Difference Water Index - Hanqiu Xu, 2006)
58   var mndwi = img.normalizedDifference(['B2','B5']).rename('MNDWI');
59

```

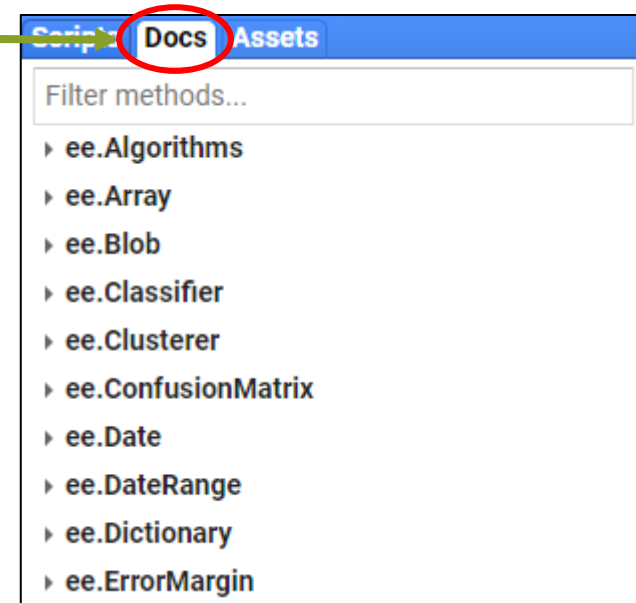
Inspector Console Tasks

Use print(...) to write to this console.



# Recursos para Ayuda

- Pestaña “Docs”
- [Developer’s Guide](#)
- [Google Earth Engine Developers Group](#)








# Series Temporales de Extensión de Manglares




# Entendiendo los Cambios a Través del Tiempo

- Podemos utilizar un análisis de series temporales para entender cómo los manglares han cambiado a través del tiempo
- Identificamos áreas de pérdida/aumento
- Entendemos patrones de cambio





# Análisis de Series Temporales

- Analizamos la misma área de estudio a lo largo de muchos años
- Enfocamos en años de interés específicos (ej.: información para ciertas décadas)
- Ejemplo: Comparación de la extensión de manglares en Colombia, 2000 vs. 2019




# Comparando Extensiones con Landsat





# Comparación de Extensiones con Landsat


- Podemos comparar los valores de diferentes índices como el Índice de Vegetación de Diferencia Normalizada (Normalized Difference Vegetation Index o NDVI) en diferentes años.
- Mayores valores del NDVI indican mayores niveles de vegetación (manglares).






# Comparando Extensiones con Landsat

- Podemos crear muestras de áreas con y sin manglares usando estas imágenes.
- El aprendizaje automático nos permite utilizar estas muestras para detectar manglares en una región.



# Clasificación “Random Forest” (Bosque Aleatorio)

- Aprendizaje Automático
  - Utiliza estadísticas para identificar patrones en grandes conjuntos de datos
  - Inteligencia artificial que “aprende” de los datos
- Ensemble, algoritmo de aprendizaje automático en base a los árboles
- Supervisada
- Usa árboles de decisión para elegir la mejor solución mediante una “votación”



Tally: Six 1s and Three 0s  
**Prediction: 1**



# La Caja Negra

Datos de Entrada  
y Entrenamiento



Algoritmo  
de  
Aprendizaje  
Automático


El algoritmo de aprendizaje automático es una “caja negra” donde solo podemos observar las entradas y salidas.

Salida



# Clasificación “Random Forest” (Bosque Aleatorio)

- El algoritmo construye un árbol de decisión para cada muestra.
- Basado en los predictores (bandas de Landsat) los árboles votarán por cada pixel para detectar manglares versus no-manglares.
- El valor más apoyado es asignado a cada píxel




Tally: Six 1s and Three 0s  
**Prediction: 1**






# Extensión de Manglares con Clasificación "Random Forest"


1) Crear Muestras



2) Ejecutar RFC



3) Refinar Modelo



# Validación de Resultados

- Después de haber creado nuestro mapa, necesitamos validarlo.
- Entender la exactitud de nuestro modelo nos permite entender qué tan fiables son nuestros resultados.
- Podemos usar muestras aleatorias estratificadas para realizar una evaluación de la precisión independiente.
- “Visitamos” cada punto y usamos imágenes satelitales para marcar si están correctos.
- Para este ejercicio, utilizaremos el plug-in Class Accuracy en QGIS 3.10:
  - <https://github.com/remotesensinginfo/classaccuracy>



Datos de  
Entrada de  
Entrenamiento




Ejecutar  
Modelo



Evaluar  
Precisión



Refinar  
Modelo




Modelo  
Final



# Área de Estudio: Guyana

- NASA y SERVIR trabajan en colaboración con organismos dentro de diferentes países como Guyana para ayudarles a monitorear los manglares.
- Guyana prevé inundaciones e intrusión de agua salada en el futuro con el aumento del nivel del mar.
- Este caso de estudio muestra cómo el mapeo de manglares puede ayudar a enfocar las prácticas de conservación.





PARA SEGUIR CON EL SCRIPT COMPLETO:

<https://code.earthengine.google.com/a2400e2ce048914ccf1b16aba2702951>





# 1) Configuración del Mapa

# Importe lo Siguiente

- Landsat 8 Surface Reflectance Tier 1
  - Colección de Imágenes: [LANDSAT/LC08/C01/T1\\_SR](#)
  - Cambiar Nombre a “L8”
- SRTM Digital Elevation Data 30m
  - Colección de Imágenes: [USGS/SRTMGL1\\_003](#)
  - Cambiar Nombre a “SRTM”



# Empiece Configurando el Mapa

Centre el mapa sobre la región de interés usando el archivo shapefile de la región.

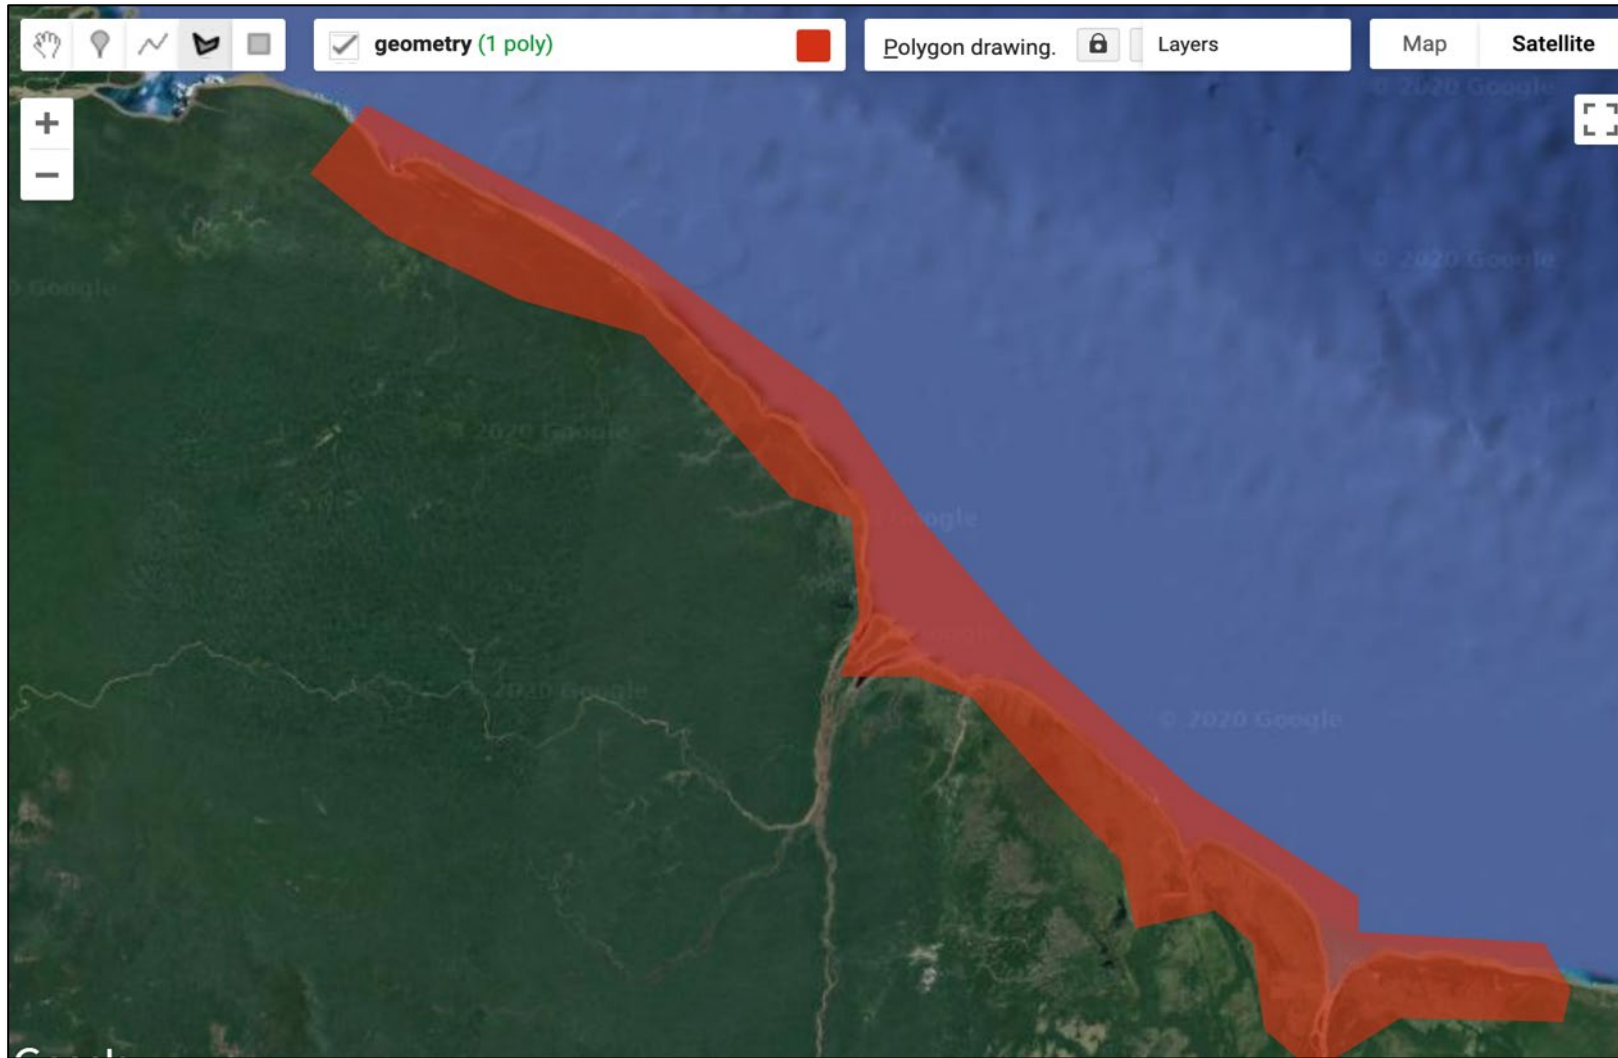
```
Map.centerObject(geometry,7)
```

```
Map.setOptions('satellite')
```





# Dibuje una Geometría para su Área de Interés







## 2) Configurando una Imagen Landsat Compuesta Filtrada

# Configurar una Imagen Landsat Compuesta Filtrada

Primero, debemos enmascarar las nubes.

Los datos de Landsat incluyen una banda 'pixel\_qa' que se puede utilizar para crear una función para enmascarar las nubes.

```
function maskClouds(image) {  
  // Los bits 3 y 5 son nubes y sombra de nubes, respectivamente.  
  var cloudShadowBitMask = ee.Number(2).pow(3).int();  
  var cloudsBitMask = ee.Number(2).pow(5).int();  
  // Obtenga la banda de pixeles QA.  
  var qa = image.select('pixel_qa');  
  // Ambas etiquetas deben estar en cero, indicando condiciones despejadas.  
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0).and(qa.bitwiseAnd(cloudsBitMask).eq(0));  
  // Regrese la imagen enmascarada, escalada a [0, 1].  
  return image.updateMask(mask).divide(10000).copyProperties(image, ["system:time_start"]);  
}
```



# Índices Espectrales

- **NDVI = Normalized Difference Vegetation Index (Rojo e IR Cercano)**
  - Cuantifica la Vegetación
- **NDMI = Normalized Difference Moisture Index (IR Cercano e IR Onda Corta)**
  - Contenido Húmedo de la Vegetación
- **MNDWI = Modified Normalized Difference Water Index (Verde e IR Onda Corta))**
  - Información sobre el Agua
- **SR = Simple Ratio (Rojo e IR Cercano)**
  - Índice de Vegetación Simple
- **Ratio54 = Band Ratio 54 (IR Onda Corta e IR Cercano)**
  - Mapea las Características del Agua
- **Ratio35 = Band Ratio 35 (Rojo e IR Onda Corta)**
  - Mapea las Características del Agua
- **GCVI = Green Chlorophyll Vegetation Index (IR Cercano y Verde)**
  - Biomasa de Hojas Verdes





# Agregar Índices Espectrales

Esta función mapea índices espectrales para el mapeo de manglares utilizando Landsat 8.

```
var addIndicesL8 = function(img) {  
    var ndvi = img.normalizedDifference(['B5','B4']).rename('NDVI'); // NDVI  
    // NDMI (Normalized Difference Mangrove Index - Shi et al 2016 - New spectral metrics for mangrove forest identification)  
    var ndmi = img.normalizedDifference(['B7','B3']).rename('NDMI');  
    var mndwi = img.normalizedDifference(['B3','B6']).rename('MNDWI'); // MNDWI (Modified Normalized Difference Water Index -  
    Hanqiu Xu, 2006)  
    var sr = img.select('B5').divide(img.select('B4')).rename('SR'); // SR (Simple Ratio)  
    var ratio54 = img.select('B6').divide(img.select('B5')).rename('R54'); // Band Ratio 54  
    var ratio35 = img.select('B4').divide(img.select('B6')).rename('R35'); // Band Ratio 35  
    var gcvi = img.expression('(NIR/GREEN)-1',{ 'NIR':img.select('B5'), 'GREEN':img.select('B3')}).rename('GCVI'); // GCVI  
    return img  
        .addBands(ndvi)  
        .addBands(ndmi)  
        .addBands(mndwi)  
        .addBands(sr)  
        .addBands(ratio54)  
        .addBands(ratio35)  
        .addBands(gcvi);  
};
```





# Filtrar Datos Landsat por Fecha

// Seleccione el año central deseado aquí

```
var year = 2019;
```

// La fecha de inicio será un año antes de año central

```
var startDate = (year-1)+'-01-01';
```

// La fecha final será un año después del año central

```
var endDate = (year+1)+'-12-31';
```



# Aplicar Filtros y Máscaras a Imágenes de Landsat 8

```
var l8 = L8.filterDate(startDate,endDate)
// Máscara para nubes y sombras de nubes
  .map(maskClouds)
// Agregar índices
  .map(addIndicesL8)
```



# Crear Compuesto de la Colección de Imágenes de Landsat

Puede crear compuestos pixel por pixel o banda por banda usando “.median()”

```
var composite = l8
```

```
// Use el reductor de medias
```

```
.median()
```

```
// Agregue la imagen compuesta a nuestra área de interés
```

```
.clip(geometry);
```



# Aplicar Máscara a Áreas de Baja Elevación y NDVI y MNDWI Altos

La máscara adicional permite enfocarnos en áreas donde es más probable que haya manglares.

```
// Adjuntar datos de SRTM a la región
    var srtmClip = SRTM.clip(geometry);
// Máscara para elevaciones menores a 65 metros
    var elevationMask = srtmClip.lt(65);
// Usar bandas de NDVI y MNDWI para crear máscaras
    var NDVIMask = composite.select('NDVI').gt(0.25);
    var MNDWIMask = composite.select('MNDWI').gt(-0.50);
// Aplicar las máscaras
    var compositeNew = composite
        .updateMask(NDVIMask)
        .updateMask(MNDWIMask)
        .updateMask(elevationMask)
```





# Visualizar Resultados


Debemos mapear la imagen compuesta de Landsat para ensamblar nuestros datos de entrenamiento.

```
// Seleccionar bandas y parámetros para la visualización
```

```
var visPar = {bands:['B5','B6','B4'], min: 0, max: 0.35};
```

```
// Agregar capa al mapa
```

```
Map.addLayer(compositeNew  
  .clip(geometry), visPar, 'Landsat  
  Composite 2019')
```




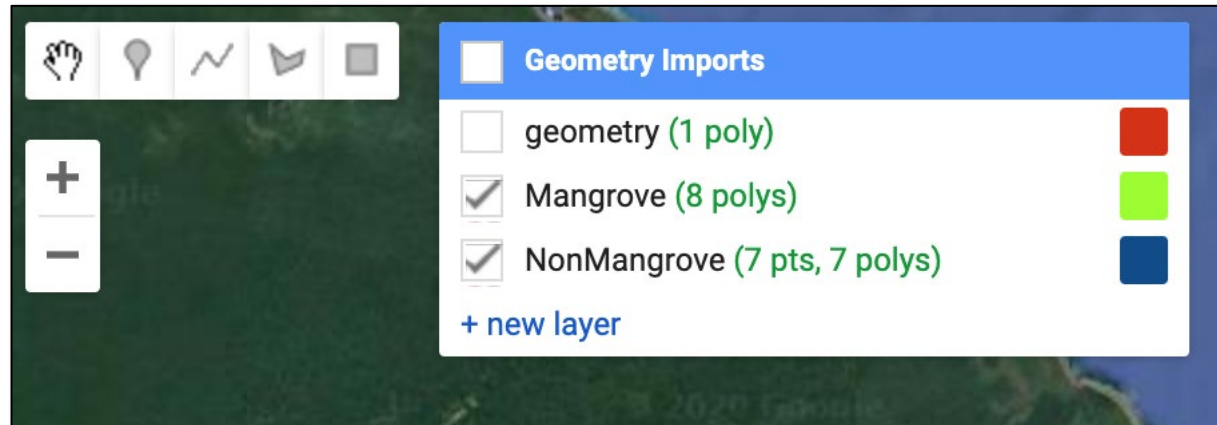


### 3) Construyendo el Modelo



# Construir una Clasificación Random Forest

Use los datos de Landsat visualizados para agregar polígonos de datos de entrenamiento.



# Preparar Datos de Entrenamiento y Predictores

// Después de dibujar polígonos de entrenamiento, combínelos

```
var classes = Mangrove.merge(NonMangrove)
```

// Defina las bandas que quiere incluir en el modelo

```
var bands = ['B5','B6','B4','NDVI','MNDWI','SR','GCVI']
```

// Cree una variable llamada "image" para seleccionar las bandas de su interés y adjuntar a la geometría

```
var image = compositeNew.select(bands).clip(geometry)
```

// Ensamble muestras para el modelo

```
var samples = image.sampleRegions({
```

```
  collection: classes, // Conjunto de geometrías para entrenamiento
```

```
  properties: ['landcover'], // Etiqueta de cada geometría
```

```
  scale: 30 // Haga cada muestra del mismo tamaño que un pixel de Landsat
```

```
}).randomColumn('random'); // Cree una columna con números aleatorios
```





# Dividir Muestras para Pruebas

Aquí dividimos nuestras muestras al azar para apartar unas para hacer la prueba de exactitud de nuestro modelo usando la columna “random” que creamos.

```
var split = 0.8; // Aprox. el 80% para entrenamiento, el 20% para pruebas  
var training = samples.filter(ee.Filter.lt('random', split)); // Crear subconjuntos  
de datos de entrenamiento  
var testing = samples.filter(ee.Filter.gte('random', split)); // Crear subconjuntos  
de datos de prueba
```



# Dividir Muestras para Pruebas

Imprima estas variables para ver cuántos datos de entrenamiento y de prueba está usando.

```
print('Samples n =', samples.aggregate_count('.all'));  
print('Training n =', training.aggregate_count('.all'));  
print('Testing n =', testing.aggregate_count('.all'));
```

Samples n = 8890	JSON
Training n = 7167	JSON
"Testing n =" 1723	Formatted



# Comenzar Clasificación Random Forest

“.smileRandomForest” se utiliza para ejecutar el modelo. Aquí ejecutamos el modelo usando 100 árboles y 5 predictores seleccionados al azar por cada división (“(100,5)”).

```
var classifier = ee.Classifier.smileRandomForest(100,5).train({
  features: training.select(['B5','B6','B4','NDVI','MNDWI','SR','GCVI',
    'landcover']), // Entrene usando bandas y propiedad de cobertura
// terrestre
  classProperty: 'landcover', // Adquiera la propiedad de cobertura Terrestre
// de las clases classes
  inputProperties: bands
});
```



# Probar el Modelo

```
var validation = testing.classify(classifier);  
var testAccuracy = validation.errorMatrix('landcover', 'classification');  
print('Validation error matrix RF: ', testAccuracy);  
print('Validation overall accuracy RF: ',  
  
testAccuracy.accuracy());
```

```
Validation error matrix RF:      JSON  
▶ [[1295,0],[0,428]]           JSON  
  
Validation overall accuracy RF:  JSON  
1
```





# Clasificar la Imagen Compuesta de Landsat Usando el Modelo Random Forest

```
var classifiedrf = image.select(bands) // seleccionar los predictores  
    .classify(classifier);  
// .classify aplica el Random Forest
```



# Reducir Ruidos en los Resultados

Puede que los resultados de los modelos sean muy “ruidosos”. Para reducir los ruidos, cree una máscara para enmascarar píxeles no conectados.

```
// Cree una imagen que muestre el número de píxeles con los que cada  
// pixel está conectado
```

```
var pixelcount = classifiedrf.connectedPixelCount(100, false);
```

```
// Filtre todos los píxeles conectados a 4 o menos
```

```
var countmask = pixelcount.select(0).gt(25);
```



# Enmascarar Resultados

Enmascare los resultados para visualizar solo extensión de manglares.

```
var classMask = classifiedrf.select('classification').gt(0)
var classed = classifiedrf.updateMask(countmask)
                        .updateMask(classMask)
```



# Mapear Resultados

Enmascarar resultados para visualizar solo extensión de manglares

```
// Agregue la clasificación al mapa
```

```
Map.addLayer (classified, {min: 1, max: 1,  
palette:'blue'}, 'Mangrove Extent 2019');
```

```
// Para comparar, agreguemos el conjunto de  
datos GMW al mapa.
```

```
var GMW =  
ee.Image('projects/mangrovescience/GuyanaG  
MW')
```

```
Map.addLayer (GMW, {min: 1, max: 1,  
palette:'green'}, 'Global Mangrove Watch');
```







## 4) Comparación de Series Temporales

# Comparación de Series Temporales

Queremos poder comparar la extensión de manglares en diferentes años para analizar si el área de manglares ha sufrido pérdidas a lo largo del tiempo.

Debemos volver a ejecutar nuestro modelo usando imágenes de Landsat de una fecha diferente con nuevos datos de entrenamiento.



# Agregando Índices Espectrales de Landsat 7

- Landsat 5 y 7 tienen diferentes números de bandas.
- Landsat 8 también recolecta imágenes en franjas más anchas.
- Necesitaremos asignar índices espectrales usando diferentes valores de bandas.



# Índices Espectrales para Landsat 8

Table 1. Landsat 8 Operational Land Imager Spectral bands

Bands	Wavelength ( $\mu\text{m}$ )	Resolution (m)
Band 1 - Coastal aerosol	0.43-0.45	30
Band 2 - Blue	0.45-0.51	30
Band 3 - Green	0.53-0.59	30
Band 4 - Red	0.64-0.67	30
Band 5 - Near Infrared (NIR)	0.85-0.88	30
Band 6 - SWIR 1	1.57-1.65	30
Band 7 - SWIR 2	2.11-2.29	30
Band 8 - Panchromatic	0.50-0.68	15
Band 9 - Cirrus	1.36-1.38	30
Band 10 - Thermal Infrared (TIRS) 1	10.6-11.19	100
Band 11 - Thermal Infrared (TIRS) 2	11.50-12.51	100





# Índices Espectrales para Landsat 7

Table 2. Landsat 7 Enhanced Thematic Mapper<sup>+</sup> Spectral bands

Bands	Wavelength ( $\mu\text{m}$ )	Resolution (m)
Band 1	0.45-0.52	30
Band 2	0.52-0.60	30
Band 3	0.63-0.69	30
Band 4	0.77-0.90	30
Band 5	1.55-1.75	30
Band 6	10.40-12.50	60 (30)
Band 7	2.09-2.35	30
Band 8	.52-.90	15
Band 1	0.45-0.52	30
Band 2	0.52-0.60	30
Band 3	0.63-0.69	30



# Agregar Índices Espectrales de Landsat 7

```
var addIndicesL7 = function(img) {  
  var ndvi = img.normalizedDifference(['B4','B3']).rename('NDVI');  
  var ndmi = img.normalizedDifference(['B7','B2']).rename('NDMI');  
  var mndwi = img.normalizedDifference(['B2','B5']).rename('MNDWI');  
  var sr = img.select('B4').divide(img.select('B3')).rename('SR');  
  var ratio54 = img.select('B5').divide(img.select('B4')).rename('R54');  
  var ratio35 = img.select('B3').divide(img.select('B5')).rename('R35');  
  var gcvi = img.expression('(NIR/GREEN)-1',{ 'NIR':img.select('B4'), 'GREEN':img.select('B2')}).rename('GCVI');  
  return img.addBands(ndvi)  
    .addBands(ndmi)  
    .addBands(mndwi)  
    .addBands(sr)  
    .addBands(ratio54)  
    .addBands(ratio35)  
    .addBands(gcvi)};
```



# Filtrar Datos de Landsat por Fecha y Región

// Seleccione el año central deseado aquí

**var** year = 2009;

// La fecha de inicio será configurada como un año antes del año central

**var** startDate = (year-1)+'-01-01';

// La fecha final será configurada como un año después del año central

**var** endDate = (year+1)+'-12-31';



# Aplicar Filtros y Máscaras

```
var l7 = L7.filterDate(startDate, endDate)
// Máscara para nubes y sombras de nubes
// Utilizamos la misma función que utilizamos para Landsat 8 para
// enmascarar nubes
    .map(maskClouds)
// Agregar los índices
    .map(addIndicesL7)
```





# Colección de Imágenes Compuestas

```
var L7composite = l7
```

```
// Use el reductor de medias
```

```
.median()
```

```
// Adjunte la imagen compuesta a nuestra área de interés
```

```
.clip(geometry);
```



# Máscara para Elevación Baja/NDVI y MNDWI Altos

```
var L7NDVIMask = L7composite.select('NDVI').gt(0.25);  
var L7MNDWIMask = L7composite.select('MNDWI').gt(-0.50);  
// Aplicar las máscaras  
var L7compositeNew = L7composite  
    .updateMask(L7NDVIMask)  
    .updateMask(L7MNDWIMask)  
    .updateMask(elevationMask) //We use the same mask
```



# Visualizar Resultados

```
// Seleccione bandas y parámetros para la visualización
```

```
// Usamos las bandas 4, 5 y 3 en vez de las otras
```

```
var L7visPar = {bands:['B4','B5','B3'], min: 0, max: 0.35};
```

```
// Agregue la capa al mapa
```

```
Map.addLayer(L7compositeNew.clip(geometry), L7visPar, 'Landsat  
Composite 2009')
```





## 5) Nuevo Modelo Random Forest



# Construir un Nuevo Modelo Random Forest

Preparar datos de entrenamiento y predictores.

// Después de dibujar los polígonos de entrenamiento, combínelos.

```
var classes2009 = Mangrove2009.merge(NonMangrove2009)
```

// Defina las bandas que quiere incluir en el modelo.

```
var L7bands = ['B4','B5','B3','NDVI','MNDWI','SR','GCVI']
```

// Cree una variable llamada “image” para seleccionar las bandas de interés y adjunte a la geometría.

```
var L7image = L7compositeNew.select(L7bands).clip(geometry)
```



# Ensamblar Muestras

```
var L7samples = L7image.sampleRegions({  
  collection: classes2009, // Conjunto de geometrías seleccionadas para el  
  entrenamiento  
  properties: ['landcover'], // Etiqueta de cada geometría  
  scale: 30 // Haga cada muestra del tamaño de un pixel de Landsat  
}).randomColumn('random'); // Cree una columna con números aleatorios
```



# Dividir Muestras para Hacer Pruebas

// Cree subconjuntos de datos de entrenamiento.

```
var L7training = L7samples.filter(ee.Filter.lt('random', split));
```

// Cree subconjuntos de datos de prueba.

```
var L7testing = L7samples.filter(ee.Filter.gte('random', split));
```

// Imprima estas variables para ver cuántos datos de entrenamiento y de prueba  
// está utilizando.

```
print('Samples n =', L7samples.aggregate_count('.all'));
```

```
print('Training n =', L7training.aggregate_count('.all'));
```

```
print('Testing n =', L7testing.aggregate_count('.all'));
```



# Iniciar Clasificación Random Forest

```
var L7classifier = ee.Classifier.smileRandomForest(100,5).train({  
  features: L7training.select(['B4','B5','B3','NDVI','MNDWI','SR','GCVI',  
  'landcover']), // Entrene usando bandas y propiedad de cobertura terrestre  
  classProperty: 'landcover', // Adquiera la propiedad de la cobertura terrestre  
  inputProperties: L7bands // de las clases  
});
```





# Clasificar Imagen Compuesta de Landsat

```
var L7classifiedrf = L7image.select(L7bands) // Seleccione los predictores
    .classify(L7classifier);

// Reduzca los Ruidos
var pixelcount = L7classifiedrf.connectedPixelCount(100, false);
var countmask = pixelcount.select(0).gt(25);
```



# Mapear Resultados

```
// Enmascare los resultados para visualizar solo extensión de manglares
```

```
var L7classMask = L7classifiedrf.select('classification').gt(0)
```

```
var L7classed=
```

```
L7classifiedrf.updateMask(countmask).updateMask(L7classMask)
```

```
Map.addLayer (L7classed, {min: 1, max: 1, palette:'green'}, 'Mangrove Extent  
2009');
```









6) Calcular Área de Manglares

# Calcular Extensión de Manglares

```
// 2009
```

```
var get2009 = L7classified.multiply(ee.Image.pixelArea()).divide(10000).reduceRegion({  
  reducer:ee.Reducer.sum(),  
  geometry:geometry,  
  scale: 100,  
  maxPixels:1e13,  
  tileScale: 16  
}).get('classification');
```

```
print(get2009, 'Mangrove Extent 2009 in ha')
```





# Calcular Extensión de Manglares

```
// 2019
```

```
var get2019 = classed.multiply(ee.Image.pixelArea()).divide(10000).reduceRegion({  
  reducer:ee.Reducer.sum(),  
  geometry:geometry,  
  scale: 100,  
  maxPixels:1e13,  
  tileScale: 16  
}).get('classification');
```

```
print(get2019, 'Mangrove Extent 2019 in ha')
```





7) Crear Puntos para la Evaluación de la Precisión

# Ejecutar Evaluaciones de la Precisión Independientes

Para probar la exactitud real del modelo en vez de la idoneidad (fit), necesitamos crear puntos de muestreo aleatorio.

```
var stratSamples = classed.stratifiedSample({  
    numPoints:150,    // Número de puntos por clase  
    classBand: 'classification',  
    region:geometry,  
    scale: 30,  
    geometries:true });
```



# Puntos de Zona de Protección (Buffer)

// Agregue una zona con un radio de 15 m alrededor de cada punto.

```
var stratBuff = function(feature) {  
    var num = feature.get('classification');  
    return feature.buffer(15).set('classification', num);  
};
```

```
var stratPoints = stratSamples.map(stratBuff)
```







8) Exportar Capas de Interés

# Exportar Capas de Interés

// Extensión de Manglares en 2019

```
Export.image.toDrive({  
  image: classed,  
  description: '2019GuyanaMangroveExtent',  
  region: geometry,  
  scale: 30,  
  maxPixels: 1e13  
});
```



# Exportar Capas de Interés

// Extensión de Manglares en 2009

```
Export.image.toDrive({  
  image: L7classified,  
  description: '2009GuyanaMangroveExtent',  
  region: geometry,  
  scale: 30,  
  maxPixels: 1e13  
});
```



# Exportar Capas de Interés

// Muestreos Aleatorios Estratificados

```
Export.table.toDrive({  
  collection: stratPoints,  
  description: 'StratifiedrandomPoints',  
  fileFormat: 'SHP',  
});
```







## 9) El plug-in “Class Accuracy” en QGIS

# El Plug-in Class Accuracy

- Class Accuracy es un Plug-in para QGIS creado por el Dr. Peter Bunting.
- Esta herramienta lleva al usuario por cada punto aleatoriamente estratificado.
- Luego el usuario determina si el punto fue clasificado de manera precisa por el modelo o no.
- El resultado es una evaluación de la precisión general del modelo.



# El Plug-In Class Accuracy en QGIS

- Abra QGIS 3.10 y agregue un mapa de base satelital (ej. Bing Aerial).
- Agregue los puntos aleatorios exportados:
  - Agregue dos columnas: Exportar y Procesados
  - Asegúrese que todas las columnas incluyendo la clasificación estén en el formato **String**.
- Abra el Plug-In Class Accuracy:
  - <https://github.com/remotesensinginfo/classaccuracy>





All



Installed



Not installed





Install from ZIP



Settings

If you are provided with a zip package containing a plugin to install, please select the file below and click the *Install plugin* button.

Please note for most users this function is not applicable, as the preferable way is to install plugins from a repository.

ZIP file:   



Accuracy Assessment Tool

1. Select a Vector Layer:  
StratifiedrandomPoints3

2. Select Columns:  
Classified Column: ClassStr  
Output Column: OutputStr  
Processed Column: ProcessStr

Visit Processed Points

3. Press Start when ready:  
Finish Start

4. Go through the features (Press Return for Next):  
Prev Next

Assign

4. Or go direct to a feature (index starts at 1):  
Go to Feature (ID): Go To

5. Change class if incorrect:  
2 of 300 0 0

6. Add extra classes to the list:  
Class Name: Add

7. Change scale:  
0.01 Update

8. Produce Error Matrix:  
Calc Error Matrix

Accuracy Assessment Tool

1. Select a Vector Layer:  
StratifiedrandomPoints3

2. Select Columns:  
Classified Column: ClassStr  
Output Column: OutputStr  
Processed Column: ProcessStr

Visit Processed Points

3. Press Start when ready:  
Finish Start

4. Go through the features (Press Return for Next):  
Prev Next

Assign

4. Or go direct to a feature (index starts at 1):  
Go to Feature (ID): 200 Go To

5. Change class if incorrect:  
200 of 300 1 0  
1

6. Add extra classes to the list:  
Class Name: Add

7. Change scale:  
0.01 Update

8. Produce Error Matrix:  
Calc Error Matrix

1. Select a Vector Layer:  
 StratifiedrandomPoints3

2. Select Columns:  
 Classified Column: ClassStr  
 Output Column: OutputStr  
 Processed Column: ProcessStr

Visit Processed Points

3. Press Start when ready:  
 Finish Start

4. Go through the features (Press Return for Next):  
 Prev Next

Assign

4. Or go direct to a feature (index starts at 1):  
 Go to Feature (ID): 1 Go To

5. Change class if incorrect:  
 300 of 300 1 1

6. Add extra classes to the list:  
 Class Name: Add

7. Change scale:  
 0.02 Update

8. Produce Error Matrix:  
 Calc Error Matrix

Overall Accuracy (%)	78							
kappa	0.71							
Counts:								
	3	0	2	1	Mixed	NA	User	
3	137	6	0	0	3	4	150	
0	34	85	8	2	11	10	150	
2	0	13	124	6	2	5	150	
1	5	11	4	122	4	4	150	
Mixed	0	0	0	0	0	0	0	
NA	0	0	0	0	0	0	0	
Producer	176	115	136	130	20	23	468	
Percentage:								
	3	0	2	1	Mixed	NA	User (%)	
3	22.83	1	0	0	0.5	0.67	91.33	
0	5.67	14.17	1.33	0.33	1.83	1.67	56.67	
2	0	2.17	20.67	1	0.33	0.83	82.67	
1	0.83	1.83	0.67	20.33	0.67	0.67	81.33	
Mixed	0	0	0	0	0	0	0	
NA	0	0	0	0	0	0	0	
Producer (%)	77.84	73.91	91.18	93.85	0	0	78	

# Repaso

Durante esta sesión, cubrimos:

- Extensión de manglares durante dos períodos de tiempo
- Evaluación de la precisión independiente del modelo

La próxima vez, cubriremos:

- Cómo crear aplicaciones para países específicos
- Ejemplos de aplicaciones de resultados



# Preguntas

- Por favor escriba su pregunta en el cuadro para preguntas.
- Publicaremos las preguntas y las respuestas en la página web de la capacitación después de la conclusión del curso.





# Contactos

- Contactos
  - Abigail Barenblitt: [abigail.barenblitt@nasa.gov](mailto:abigail.barenblitt@nasa.gov)
  - Temilola Fatoyinbo: [lola.fatoyinbo@nasa.gov](mailto:lola.fatoyinbo@nasa.gov)
- Preguntas Generales sobre ARSET
  - Ana Prados: [aprados@umbc.edu](mailto:aprados@umbc.edu)
- Página web de ARSET:
  - [appliedsciences.nasa.gov/arset](https://appliedsciences.nasa.gov/arset)





**¡Gracias!**

