



Ciencia y Tecnología
Secretaría de Ciencia, Humanidades, Tecnología e Innovación



CentroGeo
Centro de Investigación en
Ciencias de Información Geoespacial, A.C.

CENTRO DE INVESTIGACIÓN EN
CIENCIAS DE INFORMACIÓN GEOESPACIAL, A.C.

CentroGeo

Centro Público de Investigación SECIHTI

Detección de sargazo utilizando imágenes de una estación de video
monitoreo costero en Puerto Morelos, Quintana Roo, México.

TESIS

Que para obtener el grado de
Maestra en Ciencias de Información Geoespacial

Presenta

Mitsui Myrna Salgado Saito

Director de Tesis:

Dr. Oscar Gerardo Sánchez Siordia

Codirectora de Tesis:

Dra. Betsabé de la Barreda Bautista

CENTRO DE INVESTIGACIÓN EN
CIENCIAS DE INFORMACIÓN GEOESPACIAL, A.C.

CentroGeo

Centro Público de Investigación SECIHTI

Detección de sargazo utilizando imágenes de una estación de video
monitoreo costero en Puerto Morelos, Quintana Roo, México.

TESIS

Que para obtener el grado de

Maestra en Ciencias de Información Geoespacial

Presenta

Mitsui Myrna Salgado Saito

Director de Tesis

Dr. Oscar Gerardo Sánchez Siordia

Codirectora de Tesis

Dra. Betsabé de la Barreda Bautista

Sinodales

**Dr. Gandhi Samuel Hernández
Chan**

Dr. Hugo Carlos Martínez

**Mtra. Karime González
Zuccolotto**

Ciudad de México, marzo 2025

DEDICATORIA

Primero comenzaré agradeciendo a la parte Académica de esta tesis, que son mis tutores, Oscar y Betsa, gracias por sus recomendaciones. Sin su consejo, esta tesis no habría sido posible.

Al Dr. Jaime Arriaga y a su GRUPO INTERDISCIPLINARIO PARA EL ESTUDIO DEL SARGAZO por brindarnos acceso a las fotografías que hicieron posible la realización de este trabajo.

A la maestra Guadalupe que me ha guiado en todo este proceso de la tesis.

De manera personal, quiero agradecer a mis padres, quienes son mi mayor ejemplo y las personas que más me han apoyado en la vida. Muchas gracias por quererme, enseñarme e inspirarme siempre. A Mayu, quien con el tiempo se ha vuelto cada día más cercana a mí, lo cual me hace muy feliz. Los quiero mucho a los tres.


A mi tía Hanako, que siempre, siempre me apoya de muchas maneras. Gracias, tía.

A Mamá Pera, cuyo amor siento todos los días.

A mis suegros, Claudia y Noel, quienes se han convertido en parte de mi familia y me han apoyado en este nuevo camino.

A todos mis amigos, que me dan ánimos, me escuchan y hacen mi vida un poco menos pesada (los de la prepa, carrera, maestría y de la vida).

A mi esposo, Noel, quien, además de ser ahora la persona más cercana a mí, me ayudó de muchas formas en este trabajo. No solo con ideas y consejos, sino también emocionalmente en los momentos difíciles. Te amo Tonchis. Este trabajo está dedicado principalmente a ti, sin tu ayuda habría sido muy difícil terminarlo.



RESUMEN

El sargazo pelágico, compuesto principalmente por las especies *Sargassum natans* y *S. fluitans*, es una macroalga marina que, aunque desempeña un papel ecológico crucial en mar abierto, puede causar graves problemas cuando se acumula en playas y aguas litorales. Desde 2014, el caribe mexicano ha sido testigo de estos arribazones masivos de sargazo, los cuales han afectado negativamente, provocando efectos adversos en los ecosistemas costeros, la salud humana y la industria turística, que es fundamental para muchas economías de esta región.

Este trabajo presenta una metodología completa para detectar sargazo utilizando imágenes de una estación de video monitoreo costero, demostrando su efectividad a través de técnicas de Aprendizaje Automático. Se emplearon tres métodos: Máquinas de Soporte Vectorial (SVM) con kernel lineal y radial, Bosques Aleatorios (Random Forest) y una Red Neuronal Artificial de Perceptrón Multicapa (RNA MLP) para detectar sargazo en dos medios: arena y en agua. Los resultados mostraron que en arena, el modelo RNA MLP fue el más efectivo, alcanzando valores de precisión mayores a 0.86. La detección de sargazo en agua resultó ser más desafiante debido a la dificultad de distinguirlo del agua y los reflejos solares en la misma. A pesar de estos retos, el modelo Random Forest mostró el mejor desempeño, con un valores de precisión mayores a 0.72.

Los resultados obtenidos se compararon con la detección de sargazo en imágenes satelitales Sentinel-2, utilizando los índices espectrales FAI (Floating Algae Index) y NDVI (Normalized Difference Vegetation Index). Se encontraron correlaciones positivas en la detección de sargazo tanto en arena como en agua, siendo más fuertes en este último caso. El NDVI mostró una mayor correlación con las detecciones a partir de fotografías, lo cual podría deberse a la sensibilidad del FAI a aguas turbias y poca profundidad, esto en el caso del agua.

Que las detecciones tanto del sargazo en las fotografías como en las imágenes satelitales se correlacionen, se invita a considerar la fusión de estos dos métodos en el futuro para poder monitorear el sargazo. Esto permitirá obtener medidas más precisas de la cantidad de sargazo en las playas, facilitando su monitoreo y comprensión, y ayudando a mitigar sus efectos ecológicos, económicos y sociales en las costas.

ÍNDICE

DEDICATORIA	i
RESUMEN	ii
ÍNDICE	iii
LISTA DE FIGURAS	1
LISTA DE TABLAS	5
1. INTRODUCCIÓN	7
1.1 Sargazo.....	7
1.2 Problemática del sargazo en México.....	8
1.3 Detección de sargazo con percepción remota.....	10
1.3.1 Limitaciones con las imágenes satelitales y los índices espectrales.....	10
1.4 Estado del arte detección del sargazo.....	12
1.4.1 Detección Basada en Aprendizaje Automático.....	12
1.4.2 Uso de imágenes no satelitales.....	13
1.4.3 Limitaciones de los trabajos actuales.....	14
1.5 Justificación académica.....	15
2. OBJETIVOS	16
3. MARCO TEÓRICO	17
3.1 Video monitoreo en zonas costeras.....	17
3.2 Percepción remota.....	18
3.2.1 Reflectancia espectral de la vegetación.....	18
3.2.2 Índices espectrales.....	21
3.2.2.1 Índice de vegetación de diferencia normalizada (NDVI).....	21
3.2.2.2 Índice de algas flotantes (FAI).....	22
3.5 Aprendizaje Automático (Machine Learning).....	23
3.5.1 Aprendizaje supervisado.....	23
3.5.1.1 El proceso de aprendizaje supervisado y sus métricas.....	24
3.5.1.2 Árboles de decisión binarios.....	26
Índice de impureza de Gini o Índice GINI impurity.....	27
3.5.1.3 Árboles aleatorios o Random Forest.....	28
3.5.1.2 Máquinas de Soporte Vectorial (SVM).....	29
3.5.1.2.1 El truco de Kernels en SVM.....	31
• El kernel Función de base radial o RBF Radial Basis Function.....	32
• Kernel polinomial.....	33
3.5.1.3 Redes neuronales.....	34
3.5.1.3.1 Red neuronal Artificial Perceptrón Multicapa.....	36
3.5.2 Aprendizaje no supervisado.....	37
3.5.2.1 Algoritmo K-means.....	37
3.5.2.1.1 Método del codo.....	38
3.5.2.1.2 Gráfico de silueta.....	39
3.5.3 Aprendizaje semi-supervisado.....	40
3.5.4 Aprendizaje por refuerzo.....	41
3.6 Espacios de color.....	41

4. ZONA DE ESTUDIO.....	43
5. DESCRIPCIÓN DE LOS DATOS.....	44
5.1 Fotografías de las estaciones de video monitoreo.....	44
5.2 Imágenes satelitales.....	45
6. METODOLOGÍA.....	46
6.1 Detección de sargazo en las imágenes satelitales mediante el cálculo de índices espectrales.....	47
6.2 Detección de sargazo en las fotografías de la estación de video monitoreo costero....	47
6.2.1 Selección de las fotografías.....	47
6.2.1.1 Preprocesamiento de las fotografías de la EVMC.....	49
6.2.1.1.1 Método del Codo.....	50
6.2.1.1.2 Gráfico de Silueta.....	50
6.2.1.1.3 Exploración de los grupos creados a partir de K-means.....	52
6.2.1.1.4 Creación de una fotografía por día.....	54
6.2.2 Creación del conjunto de datos entrenamiento y etiquetado.....	55
6.2.3 Realización de máscaras para delimitar la región de interés.....	57
6.2.3.1 Creación de máscaras para la detección del sargazo en la Arena.....	58
6.2.3.2 Creación de máscaras para la detección del sargazo en el agua.....	58
6.2.4 Análisis de características para los modelos.....	58
6.2.5 Detección del sargazo y creación de series de tiempo.....	59
6.3 Comparación de las series de tiempo.....	61
6.3.1 Medidas de similitud entre series de tiempo.....	62
6.3.1.1 Deformación temporal dinámica.....	62
6.3.2 Descomposición de series de tiempo.....	63
6.3.3 Comparación con registros anteriores.....	64
7. RESULTADOS.....	64
7.1 Análisis de características importantes para la detección del sargazo con algoritmos de Aprendizaje Automático.....	65
7.1.1 Sargazo en arena.....	65
7.1.2 Sargazo en agua.....	65
7.1.3 Análisis de las distribuciones de RGB y HSV de los diferentes elementos que hay en las fotografías.....	66
7.2 Detección del sargazo en las imágenes del video monitoreo costero utilizando algoritmos de Aprendizaje Automático.....	68
7.2.1 Modelos sargazo en arena.....	68
7.2.2 Modelos sargazo en agua.....	71
7.3 Análisis de series de tiempo.....	74
7.3.2 Series de tiempo de la detección del sargazo en arena.....	76
7.3.2.1 Cálculo de la correlación.....	77
● Correlación cruzada.....	79
7.3.2.2 Análisis visual de las series de tiempo.....	80
7.3.2.3 Descomposición de las series de tiempo.....	83
7.3.3 Series de tiempo de la detección del sargazo en agua.....	84
7.3.3.1 Cálculo de la correlación.....	85

• Correlación cruzada.....	86
7.3.3.2 Análisis visual de las series de tiempo.....	87
7.3.3.3 Descomposición de las series de tiempo.....	89
7.3.3.4 Deformación temporal dinámica.....	90
7.3.4 Comparación con registros anteriores.....	91
7.4 Limitaciones en la detección del sargazo en las fotografías.....	93
8. DISCUSIÓN Y CONCLUSIONES.....	95
8.1 Detección del sargazo en fotografías utilizando algoritmos de Aprendizaje Automático.....	95
8.1.1 Sargazo en arena.....	95
8.1.2 Sargazo en agua.....	95
8.1.3 Discusión de la detección en ambos métodos.....	96
8.2 Análisis de series de tiempo.....	97
8.3 Ventajas y desventajas de imágenes satelitales y video monitoreo costero.....	98
8.4 Trabajo a futuro.....	99
8.5 Conclusión general.....	100
REFERENCIAS.....	101

LISTA DE FIGURAS

Figura 1.1 Fotografía del sargazo (Fotografía tomada de “México ante el sargazo, Revista de la Academia Mexicana de las Ciencias” 2020).

Figura 1.2 Mapa donde se observa el mar de sargazos, así como el Gran Cinturón de Sargazo del Atlántico o GASB (Figura tomada de López Miranda et al., 2021).

Figura 2.1 Diagrama del número de publicaciones desde el 2016 al 2023, gráfico tomado de Lazcano et al., 2023.

Figura 3.1. Diagrama del espectro electromagnético con sus longitudes de onda y sus frecuencias. Fuente: Khan Academy (<https://es.khanacademy.org/...>).

Figura 3.2 Diagrama de firmas espectrales de tres medios: vegetación, suelo y agua. Diagrama tomado de Govender et al., 2007.

Figura 3.3 Diagrama tomado de Pareek et al. 2017 en donde se muestran las firmas espectrales de tres tipos de pigmentos, Carotenoides, Clorofila a y b.

Figura 3.4 Diagrama de reflectancia espectral del sargazo para cuatro estados diferentes Fresco, mixto seco y descompuesto. Figura tomada de Chandler et al. (2023).

Figura 3.5 Diagrama de los tipos de nodos que conforman los árboles de decisión.

Figura 3.6 Diagrama que ilustra el método Bagging.

Figura 3.7 Diagramas de a) Dos clases de observaciones se muestran en el gráfico mostradas como puntos azules y rojos, también se muestran posibles planos que las dividen b) Imagen con los elementos del SVM: Hiperplano óptimo, positivo, negativo, el margen máximo y los vectores de soporte.

Figura 3.8 Diagramas de los valores diferentes del parámetro de la función de kernel radial.

Figura 3.9 Ilustración de la estructura de una neurona usada en redes neuronales.

Figura 3.10. Gráfica de dos funciones de activación comúnmente utilizadas en rojo se muestra la función sigmoide y en azul ReLU.

Figura 3.11 Arquitectura de una red neuronal con su capa de entrada, capa de salida y dos capas ocultas.

Figura 3.12. Ejemplo de tres clases diferentes agrupadas con el algoritmo K-means.

Figura 3.13 Ilustración que ejemplifica los dos tipos de distancias que se necesitan para calcular el coeficiente de silueta.

Figura 3.14. Representación del espacio de color HSV en forma de cono. Hue (H) se mide en grados (0° - 360°), Value (V) corresponde a la altura y Saturación (S) aumenta radialmente hacia el borde del cono.

Figura 4.1 Mapa que muestra la zona de estudio.

Figura 5.1 Muestra de fotografía cámara.

Figura 5.2 Imagen de a) ROI sargazo en arena b) ROI sargazo en agua, polígono creado en la plataforma de Google Earth Engine.

Figura 6.1. Diagrama en donde se muestra todo el proceso de detección del sargazo.

Figura 6.2 Fotografías del mismo día (10 de junio del 2016), se puede notar la gran variación de iluminación y de características de color en cada una.

Figura 6.3 Imagen de la izquierda muestra un ejemplo de una fotografía no óptima para la detección del sargazo. La imagen de la derecha muestra condiciones de luz y color tales que permiten diferenciar el sargazo de los elementos que lo rodean.

Figura 6.4 Diagrama que muestra el proceso de selección de fotografías con K-means

Figura 6.5 Gráfico de distorsión vs Valores de K grupos, utilizando RGB HSV.

Figura 6.6 Distintos gráficos de silueta con diferentes valores de K.

Figura 6.7 Ejemplo de fotografías de cada uno de los grupos generados por el K-means.

Figura 6.8 Diagramas de cajas de cada uno de los grupos creados con el K-means de cada una de las características de RGB y HSV.

Figura 6.9 Cantidad de fotografías de cada hora en el grupo número 2.

Figura 6.10 Fotografías promediadas, se ven algunos objetos borrosos, producto del promedio.

Figura 6.11 Máscara de etiquetado.

Figura 6.12 Fotografía en la cual se muestran los dos medios en los cuales se encuentra el sargazo.

Figura 6.13 Diagrama que muestra los conjuntos de entrenamiento y de prueba para los dos medios: sargazo en arena y sargazo en agua.

Figura 6.14 Fotografías que ejemplifican el cambio de playa antes y después del huracán A) Corresponde al 16 de febrero del 2018 (antes), B) Fotografía del 14 de noviembre del 2021 (después)

Figura 6.15 a) Imagen de la máscara para la detección de sargazo en agua, b) máscara para la detección de sargazo en arena, antes del huracán, c) máscara para la detección de sargazo de arena, después del huracán.

Figura 6.16 La máscara de agua se realizó a partir de la suma de máscaras de entrenamiento.

Figura 6.17 El conjunto de datos se compone de 6 valores de color diferentes para poder detectar el sargazo en las fotografías de cada pixel RGB y HSV.

Figura 6.18 Arquitectura de la red neuronal artificial de este trabajo.

Figura 6.19 Series de tiempo de las predicciones con RNA MLP para el sargazo en agua normalizadas antes y después del filtro Savitzky-Golay.

Figura 7.1. Gráfico de barras que muestra la importancia de cada una de las características para el modelo de sargazo arena, en el eje X se observa cada una de las características y en el eje Y su valor de reducción de impureza de Gini.

Figura 7.2. Gráfico de barras que muestra la importancia de cada una de las características para el modelo de sargazo de agua, en el eje X se observa cada una de las características y en el eje Y su valor de reducción de Gini impurity.

Figura 7.3 Histogramas que muestran la distribución de RGB de los principales elementos de la foto: arena, sargazo seco y mojado, vegetación y agua.

Figura 7.4 Histogramas que muestran la distribución de HSV de los principales elementos de la foto: Arena, sargazo seco y mojado, vegetación y agua.

Figura 7.5 Gráfico en donde se pueden visualizar las series de tiempo correspondientes a la cantidad de sargazo detectado con cada uno de los modelos, estas series de tiempo ya se encuentran suavizadas y normalizadas.

Figura 7.6 Predicciones de los distintos algoritmos de Aprendizaje Automático, los pixeles detectados como sargazo se encuentran coloreados en rojo.

Figura 7.7 Series de tiempo de los cuatro modelos de Aprendizaje Automático entrenados, donde cada uno de los puntos corresponde a la cantidad de pixeles de sargazo detectados.

Figura 7.8 Fotografías en las cuales es difícil detectar el sargazo en el agua.

Figura 7.9 Detección de sargazo en agua, con los cuatro modelos entrenados.

Figura 7.10 Gráfico de puntos en donde el eje y corresponde a la cantidad de imágenes por mes y el eje x a cada uno de los meses de nuestro periodo de estudio.

Figura 7.11 Diagramas de dispersión de las series de tiempo de las fotografías vs. los índices espectrales así como su recta ajustada en azul.

Figura 7.12 Series de tiempo adaptadas para tener el mismo número de datos. En este caso son las series generadas a partir del promedio por mes.

Figura 7.13 Series de tiempo adaptadas para tener el mismo número de datos en este caso son las series de tiempo en las cuales corresponden las fechas de la imagen satelital y la fotografía.

Figura 7.14 Diagramas de correlación cruzada, para las series de tiempo de sargazo en arena.

Figura 7.15 Series de tiempo de fechas en común, hasta arriba en azul está la serie de tiempo creada a partir de la densidad de pixeles detectados en las fotografías a partir de la RNA MLP, en verde la serie de tiempo del promedio de NDVI y en rojo del promedio del FAI.

Figura 7.16 Algunas de las fotografías que muestran comportamientos contrarios en las series de tiempo. Mientras las fotografías de la EVMC muestran grandes cantidades de sargazo en la arena, los índices espectrales muestran lo contrario.

Figura 7.17 Fotografías en las cuales se detectó gran cantidad de sargazo, tanto en las imágenes satelitales con los índices como en las fotografías de la EVMC. Del lado derecho se encuentra la imagen original, en medio la imagen con la detección de sargazo en rojo y del lado izquierdo su imagen satelital correspondiente.

Figura 7.18 Fotografía en la cual se detectó poca cantidad de sargazo en las tres series de tiempo. Del lado izquierdo se muestra la imagen original, en medio la imagen con la detección del sargazo en rojo, y del lado izquierdo su imagen satelital correspondiente.

Figura 7.19 Descomposición de las series de tiempo sargazo en arena, se muestra la tendencia, la estacionalidad y el residuo de RNA MLP, NDVI y FAI.

Figura 7.20 Series de tiempo adaptadas para tener el mismo número de datos. En este caso son las series generadas a partir del promedio por mes.

Figura 7.21 Series de tiempo adaptadas para tener el mismo número de datos en este caso son las series de tiempo en las cuales corresponden las fechas de la imagen satelital y la fotografía.

Figura 7.22 Diagramas de correlación cruzada, para las series de tiempo de sargazo en agua.

Figura 7.23 Series de tiempo de fechas en común, hasta arriba en azul está la serie de tiempo creada a partir de la densidad de pixeles detectados en las fotografías a partir de la RF, en verde la serie de tiempo del promedio de NDVI y en rojo del promedio del FAI.

Figura 7.24 Fotografía VMC del 28/12/2018 del lado derecho con la imagen satelital correspondiente del lado izquierdo.

Figura 7.25 Fotografías donde se registraron altas cantidades de sargazo, del lado derecho se ve la imagen original y en medio la fotografía con los pixeles detectados en rojo y del lado izquierdo se ve la imagen satelital

Figura 7.26 Fotografías donde se registraron pocas cantidades de sargazo del lado izquierdo y del lado derecho su imagen satelital correspondiente.

Figura 7.27 Descomposición de las series de tiempo sargazo en arena, se muestra la tendencia, la estacionalidad y el residuo de RNA MLP, NDVI y FAI.

Figura 7.28 a) Series de tiempo de nuestro trabajo correspondiente a las detecciones de sargazo en agua b) Detecciones de sargazo en arena en fotografías de EVMC c) serie de tiempo de detección de sargazo utilizando imágenes Landsat 8 . d) serie de tiempo de cantidades de sargazo removidas por los hoteles. Estas dos últimas series de tiempos fueron tomadas de Chávez et al., 2020.

Figura 7.29. a) y b) Fotografías en las cuales la cámara se veía sucia, con gotas, después de una lluvia. En la fotografía c y d se muestra una fotografía en la cual es difícil distinguir el sargazo en la arena de la vegetación.

Figura 7.30 Fotografías donde el sargazo en el agua estaba revuelto.

Figura 7.31 Fotografías donde se detectaron algunos pixeles como sargazo, pero eran personas.

LISTA DE TABLAS

Tabla 1.1 Se muestran las resoluciones temporales y espaciales de varios sensores satelitales, así como sus fechas de funcionamiento.

Tabla 3.1. Visualización en forma de tabla de un conjunto de datos, donde las x' son cada uno de los valores de las características y las y' son las etiquetas.

Tabla 3.2. Matriz de confusión con identificación de errores Tipo I y Tipo II.

Tabla 3.3 Métricas más populares para medir la precisión en algoritmos de Aprendizaje Automático.

Tabla 7.1 Valores de rendimiento F1 y exactitud evaluados con los datos de prueba de arena y agua, así como el promedio de las métricas a partir de la validación cruzada. También se muestran los tiempos de entrenamiento y predicción de cada modelo.

Tabla 7.2 Matriz de correlación entre las series de tiempo generadas a partir de los cuatro modelos entrenados en el sargazo en arena.

Tabla 7.3 Valores de rendimiento F1 y exactitud de los algoritmos entrenados para la detección del sargazo en agua, evaluados con los datos de test de agua y arena, así como el promedio de las métricas a partir de la validación cruzada. También se muestran los tiempos de entrenamiento y predicción de cada modelo.

Tabla 7.4 Distancias calculadas con DTW entre las series de tiempo generadas a partir de todos los cuatro modelos entrenados para la detección del sargazo en agua.

Tabla 7.5 Coeficientes de los ajustes de recta R y su valor P de cada par de series de tiempo.

Tabla 7.5 Coeficientes de correlación para las series de tiempo de sargazo en arena.

Tabla 7.6 Coeficientes de correlación para las series de tiempo de sargazo en arena.

Tabla 7.7 Coeficientes de correlación de Spearman entre las series de tiempo para la detección de sargazo en agua.

Tabla 7.8 Distancias calculadas entre los pares de series de tiempo con DTW.

1. INTRODUCCIÓN.

1.1 Sargazo

El sargazo pelágico o su nombre común sargazo es un conjunto de macroalgas marinas de colores pardos, cafés, verdes con diversas texturas desde rizadas laminadas o en estirpe, que se caracterizan por tener unas vesículas denominadas nematocistos las cuales al estar llenas de oxígeno les permiten flotar en la superficie del agua (SAFMC, 2002). Este género se compone de dos especies principales el *Sargassum natans* (Linnaeus) y *S. fluitans* (Børgesen) (figura 1.1).



Figura 1.1 Fotografía del sargazo (Fotografía tomada de “México ante el sargazo, Revista de la Academia Mexicana de las Ciencias” 2020).

El sargazo en el océano tiende a agruparse en pequeños o grandes grupos, desde 50 cm hasta varios kilómetros (Butler et al., 1983). Estos mantos proporcionan hábitat, refugio y sitios de alimentación para numerosas especies marinas, incluyendo peces (Stoner y Greening, 1984), tortugas marinas (Witherington et al., 2012) e invertebrados (Wells & Rooker, 2004; Huffard et al., 2014).

Anteriormente se pensaba que el sargazo se concentraba mayormente en el Mar de los Sargazos, ubicado en el Giro Subtropical del Atlántico Norte (Lapointe 1995; Gower y King, 2008, 2011). Delimitado por la Corriente del Golfo al oeste, la Corriente de Canarias al este, la Deriva del Atlántico Norte al norte y la Corriente de las Antillas al sur (Pendleton et al., 2014). Sin embargo, desde 2011 se ha observado una afluencia masiva y sin precedentes de sargazo en el Atlántico central y el mar Caribe (Franks et al., 2016; Wang et al., 2019), lo que ha generado interrogantes sobre su procedencia (Johnson et al., 2020). Estudios utilizando imágenes satelitales (Gower, Young & King, 2013; Wang et al., 2019), modelos numéricos (Johnson et al., 2013) y análisis morfológicos (Schell et al., 2015) han sugerido que estas masas de sargazo provienen de otras zonas que son: la Región de Recirculación

Ecuatorial del Norte (NERR) y el Gran Cinturón de Sargazo del Atlántico (GASB), las cuales se muestran en la figura 1.2 (Franks et al., 2016; Wang et al., 2019).

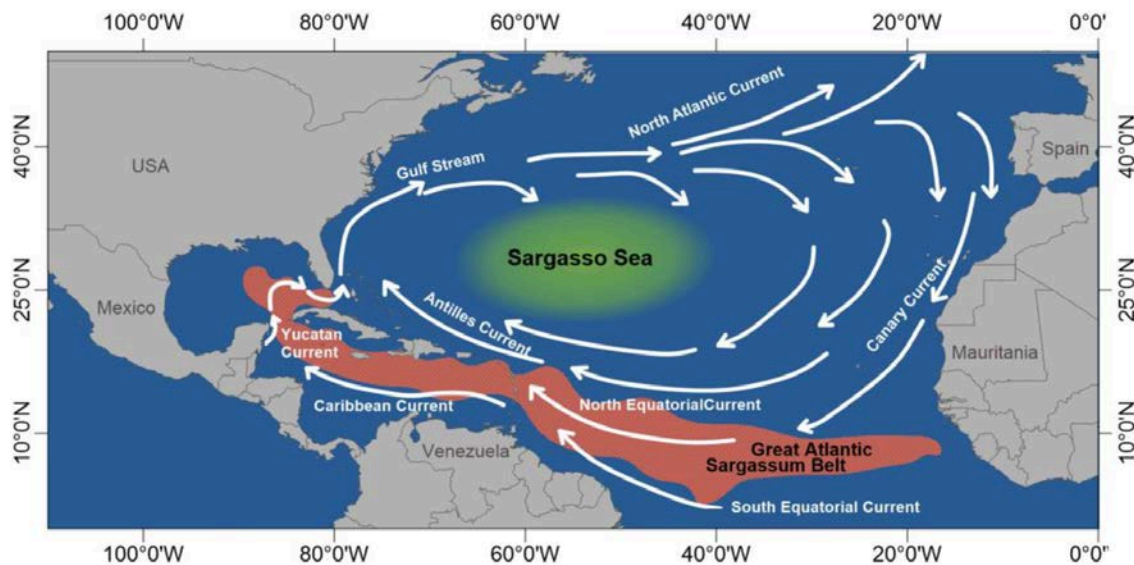


Figura 1.2 Mapa donde se observa el mar de sargazos, así como el Gran Cinturón de Sargazo del Atlántico o GASB (Figura tomada de López Miranda et al., 2021).

Varias teorías buscan explicar las posibles causas de este fenómeno. Entre ellas, se sugiere el aumento de la temperatura del agua (Magaña-Gallegos, 2023), posiblemente relacionado con el cambio climático (Sargeant, 2015; Li et al., 2024). No obstante, la teoría más aceptada apunta a la eutrofización, un proceso desencadenado por el aumento en el aporte de nutrientes como nitrógeno y fósforo en el agua, el cual promueve el crecimiento de algas (Smetacek & Zingone, 2013). Estos nutrientes adicionales pueden estar asociados con huracanes, deforestación y cambios en el uso del suelo en diversas regiones. Estas fuentes de nutrientes incluyen las desembocaduras de los ríos Amazonas, Orinoco, así como también el río del Congo (Djakouré et al., 2017; Oviatt et al., 2019). Otra posible causa es el transporte de polvo del Sahara a través de los vientos alisios, el cual aporta nutrientes al Atlántico Norte tropical. Sin embargo, se considera que el impacto de estos nutrientes es menor en comparación con los aportes de los ríos (Wang et al., 2019).

1.2 Problemática del sargazo en México.

El sargazo en mar abierto es beneficioso, ya que sirve como hábitat para numerosas especies animales y vegetales. Sin embargo, cuando se acumula en las costas y comienza a descomponerse, la materia orgánica de los organismos muertos se transforma en sustancias más simples. Este proceso, llevado a cabo por organismos descomponedores como bacterias, hongos e insectos, genera materia orgánica que deteriora la calidad de las aguas costeras. Entre los efectos negativos se encuentran la reducción de la transparencia del agua, del oxígeno disuelto y del pH (el cual es un indicador de la acidez o alcalinidad del agua), así como el aumento de compuestos como el azufre y el amoníaco (van Tussenbroek et al., 2017). Estos cambios impactan los ecosistemas costeros, afectan la salud humana y perjudican la industria turística, que constituye el principal motor económico de la región

(Rodríguez-Martínez et al., 2016; Van Tussenbroek et al., 2017; Chávez et al., 2020; Devault et al., 2021; Oxenford et al., 2021).

En cuanto a las afectaciones que causa a los ecosistemas costeros, estas son provocadas principalmente por la acumulación del sargazo y su descomposición, lo que provoca que el agua marina costera se torne café, lo que reduce la luz y el oxígeno matando diferentes especies entre ellas peces, crustáceos, equinodermos, moluscos y poliquetos (Van Tussenbroek et al., 2017; Rodríguez-Martínez et al., 2019). De igual manera, se ha observado que la erosión de la playa debido a la acumulación del sargazo, aunado al mal manejo de las máquinas utilizadas para limpiar las playas, han afectado a las áreas de anidación y alimentación de las tortugas (Chavez et al., 2020).

Las acumulaciones de sargazo también pueden provocar daños a la salud humana, debidos principalmente a la producción de gases tóxicos de la descomposición, los cuales pueden provocar problemas respiratorios y neurológicos (Resiere et al., 2019). Además, el sargazo está asociado a ciertas bacterias, u organismos como los hidroides los cuales pueden generar erupciones que son dañinas para la piel (Mendoza-Becerril et al., 2020).

Desde una perspectiva socioeconómica, las acumulaciones de sargazo en las playas han afectado principalmente a la industria turística. Esto es un serio problema, ya que esta es la principal fuente de ingresos de la región, donde sus playas se tornan de color café y con un olor fétido, ahuyentando a los turistas, debido al sargazo descompuesto (Chavez et al., 2020). A partir de este problema sectores gubernamentales y privados han tenido que invertir muchos recursos para limpiar las playas, provocando pérdidas significativas de dinero (Espinoza & Li, 2020). Por ejemplo, en 2018, los hoteles en el Caribe mexicano gastaron entre US\$128,770 y US\$284,830 por kilómetro cuadrado en limpieza (Salter et al., 2020), y en Puerto Morelos se han gastado alrededor de US\$70,000 de mayo a agosto de cada año, desde que empezó este problema, para mantener las playas limpias (Rodríguez-Martínez et al., 2023).

En el caso específico de México, el primer arribo masivo de sargazo pelágico a la costa inició a principios del verano de 2014 (Rodríguez-Martínez et al., 2016; Cuevas et al., 2018) desde ese año se han registrado otros arribos masivos en los años 2015, 2018 y 2019 (Chávez et al., 2020). Por lo tanto, para evitar la acumulación del sargazo y las afectaciones que provoca, es fundamental monitorear y comprender sus dinámicas. Actualmente, existen algunas iniciativas tanto de la sociedad civil como de sectores gubernamentales dedicadas a este fin. Entre ellas destaca el desarrollo del "semáforo del sargazo" a nivel municipal, así como la RED de Monitoreo del Sargazo de Cancún, una plataforma con más de 100,000 seguidores, donde semanalmente se publican reportes sobre el estado del sargazo, actualizados con la participación de residentes, visitantes y turistas. Empresarios locales también contribuyen compartiendo fotografías diariamente. Además, el observatorio ciudadano del sargazo realiza reportes periódicos semanales de la llegada del sargazo y la Secretaría de Marina (SEMAR) ha implementado su propio semáforo, donde cada semana emite un reporte. Estos monitoreos están basados en diferentes métodos y técnicas, los cuales se abordarán en las siguientes secciones.

1.3 Detección de sargazo con percepción remota

Los estudios iniciales sobre la detección de sargazo mediante percepción remota se basan en el principio del "borde rojo", un fenómeno caracterizado por el cambio brusco en la reflectancia que se produce entre las longitudes de onda del espectro visible (rojo) y el infrarrojo cercano (NIR). Esta transición es especialmente notable en la vegetación y aparece como un cambio abrupto en la reflectancia en esta región del espectro. Específicamente, la vegetación sana tiende a absorber la luz en la región roja del espectro (alrededor de 680 nm) debido a la presencia de clorofila, mientras que refleja fuertemente en la región del NIR, entre 700 y 730 nm (Gower et al., 2013).

A partir del principio del borde rojo, han surgido diversos índices, los cuales se han empleado ampliamente para la detección y monitoreo de vegetación. En el caso del sargazo, el "borde rojo" también resulta útil, ya que las algas flotantes, como el sargazo, también son vegetación por lo que tienen los mismos comportamientos espectrales, lo que facilita su identificación en imágenes satelitales. Gower et al. fueron los primeros en utilizar este principio en 2006 con imágenes del sensor MERIS. Posteriormente, en 2013, los mismos autores aplicaron el Índice de Clorofila Máxima (MCI), basado en el mismo principio, para identificar una nueva región de acumulación de sargazo en el océano.

Por otro lado, Hu (2009) desarrolló el Índice de Algas Flotantes (FAI), en el cual utiliza el efecto del borde rojo en conjunto con el infrarrojo cercano de onda corta (SWIR por sus siglas en inglés). Aunque efectivo, el índice FAI no cuenta con un método eficaz de enmascaramiento de nubes, lo que llevó al desarrollo del AFAI (Alternative FAI) que mejora este aspecto, enmascarando las nubes con combinaciones de bandas (Wang et al., 2016).

La percepción remota ha facilitado el monitoreo de las llegadas masivas de sargazo en el Caribe Mexicano y ha permitido identificar los patrones de acumulación de esta alga. No obstante, al utilizar imágenes satelitales se han identificado ciertas limitaciones que afectan la precisión de las detecciones, además de limitar la capacidad para realizar un monitoreo continuo y detallado en la costa, donde las consecuencias del sargazo son más severas. A continuación, se presentan las principales limitaciones de las imágenes satelitales en este contexto.

1.3.1 Limitaciones con las imágenes satelitales y los índices espectrales

Las imágenes satelitales y los índices espectrales han sido fundamentales para comprender las dinámicas del sargazo, ya que permiten su detección en áreas remotas del océano. Sin embargo, presentan limitaciones relacionadas con su resolución temporal y espacial (Rodríguez-Martínez et al., 2022), así como con factores atmosféricos inherentes a las imágenes satelitales, como sombras, destellos solares y nubes, los cuales afectan la precisión en la detección del sargazo.

En cuanto a la resolución espacial, la dificultad surge a partir de que algunos parches de sargazo miden solamente un par de metros o incluso pueden medir menos, por lo que estos no pueden ser adecuadamente detectados por los satélites de resolución media, y por lo tanto se subestima la cantidad de sargazo detectado (Ody et al., 2019). Otro desafío es la resolución temporal ya que la mayoría de los satélites utilizados tienen periodos de revisita

de varios días, lo que impide un monitoreo diario. Esto sumado a fenómenos naturales como nubes, sombras y destellos solares pueden reducir significativamente la cantidad de imágenes utilizables (Valentini et al., 2020). En la tabla 1.1 se muestran las características y resoluciones de algunos de los sensores satelitales más utilizados.

Tabla 1.1 Se muestran las resoluciones temporales y espaciales de varios sensores satelitales, así como sus fechas de funcionamiento.

	Sensor					
	MODIS	MERIS	VIIRS	Landsat 8	Sentinel - 2	Planet
Resolución espacial (m)	250 500 1000	300 1200	370 740	30 15	10 20 60	3
Resolución temporal	2 días diario	3 días	12 horas	16 días	5 días	Diario
Fechas de funcionamiento	Terra: 1999-actualidad Aqua: 2002- actualidad	2002-2012 Envisat	2011-actualidad	2013-actualidad	2015-actualidad	2015-actualidad

Estas limitaciones pueden superarse utilizando imágenes satelitales provenientes de satélites comerciales, los cuales tienen mejores resoluciones tanto temporales como espaciales. En la literatura se observa que ya se han utilizado imágenes de los satélites Planet Scope. Por ejemplo, Wang et al. (2021) reconocen la efectividad y el poder de utilizar imágenes de alta resolución. Así como Foody et al., 2021 quienes desarrollan un sistema para monitorear el sargazo utilizando estas imágenes en combinación con Sentinel-2. Sin embargo, estos productos suelen ser de acceso restringido, tener una cobertura limitada, y ser costosos, lo que los hace poco sostenibles en monitoreos a largo plazo (Lazcano et al., 2023).

En cuanto a la detección con índices espectrales, el problema principal radica en algunos elementos que pueden generar falsos positivos al detectar el sargazo, tales como nubes, reflejos, olas. Adicionalmente, Hu (2015) menciona que al intentar utilizar índices espectrales, tales como el NDVI o el FAI, el sargazo no es el único organismo marino que provoca un incremento en la reflectancia del espectro rojo; hay otras especies de vegetación marina, tales como *Trichodesmium* o la hierba marina flotante *Syringodium*, así como otros materiales flotantes como desechos marinos, basura o aceite emulsionado, que pueden causar el mismo comportamiento de reflectancia y, por lo tanto, generar falsos positivos en nuestros resultados.

Este problema se amplifica en la zona de costa o de la playa, donde al tener aguas poco profundas hay grandes cantidades de partículas suspendidas, los cuales pueden causar interferencia en la señal de absorción o reflexión de la luz. Esto es problemático porque

justamente es importante conocer las dinámicas del sargazo en esta zona. Estas dificultades provocan que a menudo no haya observaciones válidas de sargazo en zonas cercanas a la costa (Wang & Hu, 2020).

1.4 Estado del arte detección del sargazo

A partir de la necesidad de entender y monitorear los mantos de sargazo, el número de publicaciones científicas enfocadas en la detección y monitoreo de esta alga ha incrementado significativamente en los últimos años, como se puede ver en la figura 2.1 tomada de Lazcano (2023). Esta detección se ha hecho principalmente utilizando imágenes satelitales, sin embargo, han surgido nuevas metodologías de detección de sargazo con el objetivo de mejorar la precisión (Arellano-Verdejo et al., 2019; Valentini & Balouin, 2020; Rutten et al., 2021; Shin et al., 2021, Wang et al., 2021; Vázquez et al., 2021). Estas nuevas propuestas incluyen la incorporación de métodos de aprendizaje automático, así como la integración de otro tipo de imágenes no satelitales.

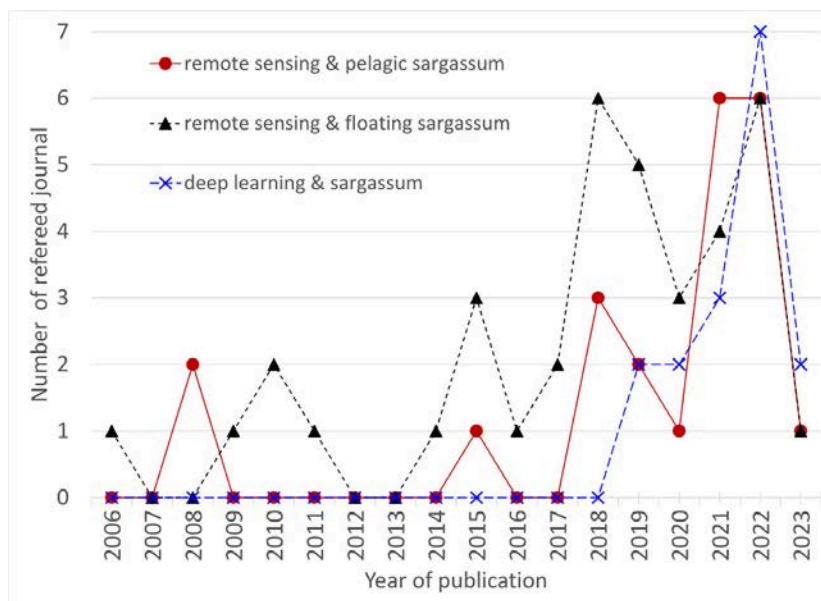


Figura 2.1 Diagrama que muestra el número de publicaciones desde el 2006 al 2023, gráfico tomado de Lazcano et al., 2023.

1.4.1 Detección Basada en Aprendizaje Automático

Los métodos de Aprendizaje Automático, o Machine Learning (ML, por sus siglas en inglés), comprenden una serie de procedimientos computacionales que, a partir de operaciones lógicas o binarias, aprenden a realizar tareas específicas mediante el análisis de ejemplos. Su principal objetivo es identificar patrones dentro de un conjunto de datos (Michie et al., 1995). Estos patrones pueden emplearse para clasificar observaciones en distintas

categorías o para predecir valores de nuevas observaciones. En el caso de la detección de sargazo, los modelos ML se utilizan para identificar su presencia en imágenes de diversas fuentes, incluidas imágenes satelitales y fotografías de distintos tipos.

El primer trabajo publicado en el campo del Aprendizaje Automático para la detección del sargazo, es el de Cuevas et al., 2018, quien utiliza una combinación de índices espectrales e imágenes Landsat 8 para entrenar el algoritmo Random Forest. A partir de este trabajo han surgido otros artículos: Por ejemplo, Shin et al., 2021 quienes entrenan tres algoritmos tradicionales de aprendizaje (Support Vector Machine (SVM), Random Forest y Gentle boosting), utilizando imágenes del satélite coreano RhoC GOCI-II y 12 bandas espectrales diferentes.

El aprendizaje profundo también ha sido explorado con la creación de redes neuronales como, por ejemplo: ERisnet (Arellano-Verdejo et al., 2019), que utiliza píxeles de imágenes MODIS y una combinación de 7 bandas de diferentes longitudes de onda, alcanzando rendimientos superiores al 90% en la detección. Wang et al. (2021) entrenan una red UNet utilizando el FAI y RGB en imágenes de alta resolución que son: OLI (Operational Land Imager) de Landsat 8, MSI Multispectral Instrument de Sentinel-2 y PlanetScope. En este trabajo se comparan las detecciones realizadas a partir de imágenes de alta resolución contra las detecciones de MODIS, y se concluye que para no subestimar la cantidad de sargazo es importante utilizar imágenes con mejores resoluciones espaciales. Laval et al. (2023) desarrollaron una red neuronal con imágenes Sentinel 2 y 3, capaz de detectar agregaciones de sargazo más pequeñas que las redes anteriores.

A partir de estos artículos, se concluye que la capacidad de combinar diversas características, como bandas electromagnéticas, índices espectrales, fechas, ubicaciones y resoluciones, permite entrenar modelos de Aprendizaje Automático con gran versatilidad y eficacia. Esta capacidad para reconocer patrones en conjuntos de datos complejos puede mejorar significativamente la precisión en la detección del sargazo.

1.4.2 Uso de imágenes no satelitales

Si bien las imágenes satelitales han sido fundamentales para el monitoreo del sargazo, como se mencionó anteriormente, presentan varias limitaciones. Estas limitaciones hacen que sea difícil realizar un seguimiento continuo y preciso del sargazo en regiones críticas, como las playas y aguas litorales, donde el impacto es más directo. Por ello, se ha comenzado a explorar el uso de imágenes no satelitales, que ofrecen mejores resoluciones y una mayor capacidad de monitoreo local. Estas imágenes incluyen aquellas provenientes de estaciones de video monitoreo costero y fotografías tomadas por usuarios, las cuales han demostrado ser útiles para mejorar la precisión de la detección de sargazo.

En cuanto a las estaciones de video monitoreo costero (EVMC), estas consisten principalmente en cámaras fijas que toman fotografías recurrentes de la playa con el objetivo de monitorear diferentes fenómenos costeros. Valentini & Balouin (2020), emplearon redes neuronales convolucionales para detectar sargazo en fotografías de una video estación. Este artículo concluye que estas imágenes pueden utilizarse para la detección de sargazo con precisiones superiores al 75%.

Otro trabajo relevante es el de Rutten et al. (2021), quienes utilizaron fotografías de la estación de video monitoreo costero en Puerto Morelos, (la misma que se emplea en esta tesis) para estudiar las dinámicas del sargazo en relación con variables como el viento y la marea. Aunque entrenaron un algoritmo SVM para la detección de sargazo, ellos mismos señalan que no lograron desarrollar un algoritmo capaz de detectarlo automáticamente.

Algunos estudios han aprovechado las fotografías tomadas por diversas personas, destacando aquellas obtenidas a través de programas de ciencia ciudadana para desarrollar metodologías de detección. Estos programas tienen como objetivo recolectar fotografías tomadas por ciudadanos que muestren la presencia de sargazo en las playas. Por ejemplo, Arellano-Verdejo et al. (2021), entrenaron redes neuronales convolucionales utilizando imágenes recolectadas a través de un programa llamado "Collective View". Estas redes permitieron discriminar entre imágenes con o sin sargazo y geolocalizar las imágenes en un mapa. Por otro lado, Putman et al. (2023) que utilizaron fotografías del proyecto "Sargassum Watch" para intentar mejorar el monitoreo satelital del sargazo, un enfoque que, aunque prometedor, no arrojó resultados concluyentes. Por otro lado, aunque no utilizaron imágenes provenientes de un programa de ciencia ciudadana, Vázquez et al. (2021) utilizaron imágenes de redes sociales como Facebook e Instagram, además de otros foros, para construir redes convolucionales capaces de detectar sargazo y a diferencia de otros estudios, estas redes pudieron clasificar las imágenes según la cantidad de sargazo presente (nulo, poco, medio, mucho, y excesivo).

1.4.3 Limitaciones de los trabajos actuales.

Los trabajos que emplean algoritmos de Aprendizaje Automático ofrecen herramientas potentes para identificar patrones y relaciones entre características clave, facilitando así la detección del sargazo. Sin embargo, presentan desafíos recurrentes, como el sobreajuste (overfitting), que ocurre cuando un modelo se ajusta excesivamente a los datos de entrenamiento y pierde capacidad de generalización para predecir nuevas observaciones. Además, estos algoritmos suelen requerir grandes cantidades de datos, y en muchos casos, datos etiquetados, lo cual implica una considerable inversión de tiempo y recursos. En el ámbito de la detección de sargazo por medio de aprendizaje automático, aún se necesita profundizar más. Por ejemplo, Lazcano et al. (2023) señalan que varios estudios carecen de una especificación detallada de los parámetros de ajuste de los algoritmos y no explican adecuadamente la evaluación e interpretación de sus resultados. Tampoco abordan cómo manejan el sobre entrenamiento y el sobreajuste, lo cual dificulta la reproducibilidad de sus experimentos y la comprensión precisa del alcance de sus hallazgos.

Con respecto a la incorporación de imágenes de EVMC, aunque prometedores, también presentan sus propios desafíos. En primer lugar, estas cámaras proporcionan una vista local de la playa, por lo que no se cuenta con información previa a la llegada del sargazo. Además, Lazcano et al. (2023) señala que mantener este tipo de sistemas es computacional y económicamente costoso. Otros factores incluyen las condiciones de luz y el color variable en las fotografías, lo que puede dificultar la precisión y generalización de un modelo automático de detección de sargazo. Estos problemas se agravan al trabajar con fotografías tomadas por participantes de programas de ciencia ciudadana, donde la variabilidad en las imágenes es mucho mayor, ya que son capturadas por diferentes personas, con diversas resoluciones, ángulos y estilos de toma de fotografía. Además, el flujo y la cantidad de

fotografías no es constante, a diferencia de las EVMC, donde las fotografías se obtienen constantemente según lo que se le programe. Sin embargo, si ambas fuentes de imágenes se procesan adecuadamente, pueden ser beneficiosas.

Es importante mencionar que ya existen publicaciones utilizando las fotografías de la EVMC de Puerto Morelos (Rutten et al., 2021; Putman 2023) con el objetivo de encontrar alguna relación entre los arribos de sargazo con factores como la velocidad del viento o el oleaje. Para esto tuvieron como objetivo secundario el detectar el sargazo en las fotografías, no obstante, Rutten et al. (2021) señala que no fue posible desarrollar un algoritmo automático para la detección de sargazo debido a las diferencias de color del sargazo y del agua. Además, menciona que manualmente se seleccionaron las fotografías a clasificar, pero no da mucho detalle con respecto a su selección, ni en los ajustes de su algoritmo lo que dificulta la reproducción del experimento (Lazcano et al., 2023).

Lo anterior demuestra que aún hay pocos artículos que utilizan este tipo de estaciones de monitoreo costero, lo que dificulta la consistencia y generalización de sus resultados. Por lo tanto, es necesario realizar más estudios que profundicen en sus metodologías de detección y que, además, puedan ser aplicados de manera práctica y efectiva,

1.5 Justificación académica

En resumen, la detección de sargazo ha sido tradicionalmente abordada mediante estudios que utilizan imágenes satelitales. Estos estudios presentan metodologías sólidas y reproducibles, y son especialmente útiles para detectar sargazo en zonas remotas del océano. Sin embargo, tienen limitaciones debido a su baja resolución espacial y temporal. Por estas razones, las fotografías provenientes de EVMC pueden ser un complemento para las imágenes satelitales, además de proporcionar información detallada sobre la presencia de sargazo en la playa, una zona difícil de monitorear por satélite.

No obstante, existe una escasez de estudios que profundicen en la metodología de detección utilizando las fotografías obtenidas de EVMC. Esta falta de investigación hace que sea difícil entender el alcance de estas fotografías y su efectividad en el monitoreo continuo y efectivo del sargazo.

Aquí entra la importancia de este trabajo, primeramente, porque presenta una metodología detallada para detectar y cuantificar el sargazo de manera automática en la zona de la playa, utilizando fotografías de una EVMC. Además, calcula la correlación de la información obtenida de estas fotografías con la obtenida mediante índices espectrales, con el fin de evaluar el desempeño de la detección en las fotografías.

Para lograr esto se utilizaron dos diferentes tipos de fuentes de datos: imágenes Sentinel-2 y fotografías tomadas a partir de una EVMC costero del Laboratorio de Ingeniería y Procesos Costeros del Instituto de Ingeniería de la Universidad Nacional Autónoma de México que además son mantenidas por Servicio Académico de Monitoreo Meteorológico y Oceanográfico SAMMO.

Con las imágenes Sentinel-2 se calcularon dos índices espectrales: el índice de algas flotantes FAI y el Índice de vegetación de diferencia normalizada. Para detectar el sargazo en las fotografías de la EVMC se utilizaron tres métodos de Aprendizaje Automático

ampliamente utilizados que son: Máquinas de Soporte Vectorial (SVM por sus siglas en inglés), Bosques aleatorios o Random Forest y una Red Neuronal Artificial de Perceptrón Multicapa (RNA Multicapa)

Donde el objetivo principal de toda esta investigación es contribuir a la comprensión de la dinámica del sargazo mediante su detección y monitoreo, para así poder mitigar las afectaciones ecológicas, socioeconómicas y de salud que provocan sus acumulaciones en las playas mexicanas.

2. OBJETIVOS

Objetivo General

Detectar sargazo en fotografías de baja resolución capturadas desde una estación de monitoreo costero en Puerto Morelos, Quintana Roo, México, aplicando técnicas de Aprendizaje Automático.

Objetivos Específicos:

Implementar y Evaluar Algoritmos de Aprendizaje Automático:

Desarrollar e implementar tres algoritmos de Aprendizaje Automático (Máquinas de Soporte Vectorial, Random Forest y Redes Neuronales) para la detección de sargazo en fotografías de EVMC. Evaluar las ventajas y desventajas de cada método para identificar sus fortalezas en términos de precisión y eficiencia.

Comparar la detección de Sargazo en fotografías de la EVMC con Imágenes Satelitales Sentinel-2 mediante Índices Espectrales:

Comparar las detecciones de sargazo en fotografías de EVMC con las obtenidas a partir de imágenes satelitales Sentinel-2 mediante los índices espectrales NDVI y FAI. Este análisis se realiza a través de series temporales de ambas fuentes para identificar similitudes y diferencias, explorando las posibles causas de estas variaciones. Además, se calculan coeficientes de correlación entre las series de ambas fuentes para evaluar el desempeño y la precisión de la detección en las fotografías de EVMC.

Estos objetivos contribuyen a una mejor comprensión de las formas de detección del sargazo, ofreciendo un análisis detallado de las fortalezas y limitaciones de los métodos utilizados, que permitirán dar un paso más hacia un monitoreo más eficaz y completo del sargazo, así como la comprensión de la dinámica del mismo.

3. MARCO TEÓRICO

3.1 Video monitoreo en zonas costeras.

Los Sistemas de Video Monitoreo Costero, han sido sistemas clave para estudiar procesos cercanos a la costa y analizar su dinámica (Holland et al., 1997; Holman y Stanley, 2007). En el caso del sargazo, pueden ser muy útiles ya que permiten monitorear la llegadas masivas del sargazo, al capturar imágenes de manera constante. Están conformados por una serie de cámaras ubicadas en puntos elevados cerca de la costa las cuales capturan fotografías de manera constante y están conectadas a un servidor en línea, lo que facilita la adquisición y almacenamiento continuo de datos (Berriel-Bueno, 2018). Gracias a esta recopilación ininterrumpida de imágenes, es posible observar los cambios dinámicos que ocurren en el entorno costero, permitiendo una descripción detallada de la línea de costa (Jóia Santos et al., 2020).

La mayoría de estos sistemas proporcionan tres productos distintos: una imagen instantánea, el promedio de la imagen y la varianza. Estos dos últimos productos permiten estudiar los píxeles que experimentaron las mayores variaciones a lo largo del tiempo y se conocen como Timex y Variance, respectivamente (Jóia Santos et al., 2020).

Existen varios sistemas de video monitoreo costero que han sido desarrollados, cada uno con características y capacidades específicas. Entre los más destacados se encuentra Argus, el primer sistema de video monitoreo costero ampliamente adoptado, desarrollado por el Laboratorio de Imágenes Costeras (CIL) de la Universidad Estatal de Oregón. A partir de este sistema, han surgido otras plataformas como SIRENA (Nieto et al., 2010), COSMOS (Taborda Silva, 2012), Beachkeeper (Brignone et al., 2012), Horus (Osorio et al., 2012), entre otros.

Un sistema de monitoreo costero se puede dividir principalmente en tres partes principales (Simarro et al., 2017):

- Adquisición de imágenes: se refiere al proceso de captura de imágenes a partir de diferentes cámaras y las almacena en un servidor central utilizando protocolos de comunicación estándar.
- Transformación de la imagen al mundo real: Para tener medidas más precisas del proceso físico a medir es necesario calibrar estos sistemas y así obtener información cuantitativa precisa de los procesos físicos.
- Aplicaciones: Se refiere a la aplicación que se les dará a los productos anteriores, ya sea estudios de la arena, oleaje o monitoreo de sargazo en este caso.

Las imágenes tomadas por estos sistemas tienen varias ventajas a comparación de las imágenes satelitales tales como: mejores resoluciones temporales y espaciales, un campo de visión más pequeño pero óptimo, que permite evitar la cobertura de nubes y los retrasos temporales, facilitando el estudio de grandes series temporales (Valentini & Balouin, 2020). Estas características resultan especialmente valiosas para la detección de sargazo, ya que permiten un monitoreo constante y detallado de su llegada a las playas. Además, su implementación suele ser relativamente menos costosa en comparación con otros métodos de teledetección como LiDAR (Light detection and ranging), escáner láser terrestre

(RTK-DGPS) entre otros, que requieren equipamiento más complejo para capturar datos automáticos, continuos y periódicos, incluso en condiciones climáticas adversas (Montes et al., 2018). Sin embargo, los sistemas de video monitoreo también presentan desventajas, como los costos de instalación y mantenimiento, además de los problemas que pueden surgir debido a la acumulación de suciedad y sedimentos en los lentes de las cámaras.

3.2 Percepción remota.

La percepción remota se define como el proceso de obtener información sobre un objeto sin requerir contacto físico directo con él. Esta información se adquiere mediante la detección y medición de los cambios que dicho objeto induce en el entorno circundante, ya sea en forma de señales electromagnéticas, acústicas, u otras (Elachi, 2021).

Esta tesis se enfoca en los sensores que detectan energía electromagnética, la cual se transmite en forma de ondas o partículas conocidas como fotones y se manifiesta en diferentes longitudes de onda, las cuales en conjunto constituyen el espectro electromagnético.

El espectro electromagnético abarca desde las ondas con las longitudes más pequeñas, como los rayos gamma con longitudes de onda menores a 10^{-12} , hasta las ondas de radio con longitudes de onda mayores a 1 metro. Entre estos extremos se encuentran los rayos X, la región ultravioleta, la región visible, el infrarrojo y las microondas, que se pueden observar en la figura 3.1 junto con sus respectivas frecuencias.

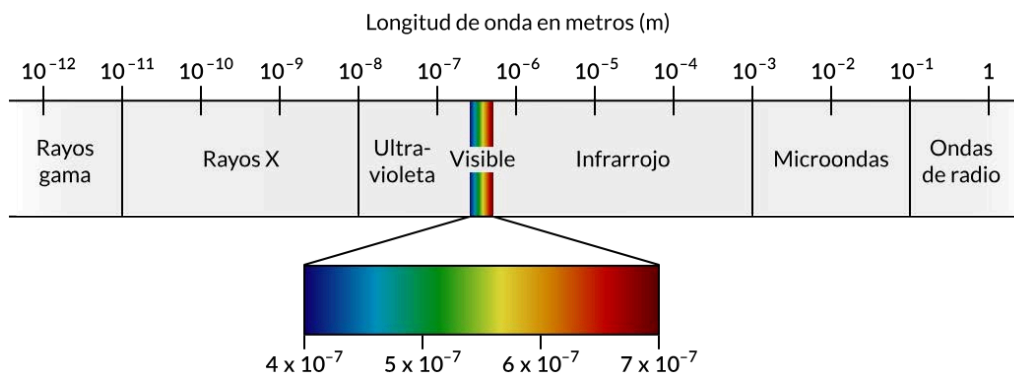


Figura 3.1. Diagrama del espectro electromagnético con sus longitudes de onda y sus frecuencias. Fuente: Khan Academy ([https://es.khanacademy.org/...](https://es.khanacademy.org/)).

3.2.1 Reflectancia espectral de la vegetación.

Los satélites de percepción remota recopilan información sobre diversos elementos en la Tierra al analizar cómo distintos materiales reflejan y absorben las longitudes de onda del espectro electromagnético. Este comportamiento genera patrones únicos conocidos como firmas espectrales (Shaw et al., 2003). En la Figura 3.2 se presenta un diagrama donde el

eje x representa la longitud de onda y el eje y la reflectancia de la luz en diferentes superficies. Y donde se muestran las firmas espectrales de tres tipos de superficies: suelo seco, vegetación verde y cuerpos de agua claros. Las diferencias entre estas firmas permiten distinguir distintos materiales con base en su respuesta espectral.

Aprovechando las características específicas de las firmas espectrales, es posible utilizar la percepción remota para detectar diferentes elementos de nuestro planeta.




Figura 3.2 Diagrama de firmas espectrales de tres medios: vegetación, suelo y agua. Diagrama tomado de Govender et al., 2007.

En el caso de la vegetación, los factores que determinan la absorción y reflexión de la luz son sus pigmentos fotosintéticos, el contenido de agua y la estructura celular de la planta. Los pigmentos fotosintéticos son moléculas que absorben la luz en longitudes de onda específicas del espectro electromagnético y reflejan otras. Entre estos pigmentos, los carotenoides y las clorofilas son los más importantes. Las clorofilas son esenciales porque convierten la energía solar en energía química, la cual es utilizada para sintetizar carbohidratos esenciales, como la glucosa, que sirven como fuente de alimento para la planta (Hynninen y Leppakases, 2002).

Aunque aún no se conocen todos los tipos de clorofilas, las clorofilas a y b son las principales (Pareek et al., 2017). En el diagrama de la figura 3.3, se muestra la firma espectral en la porción visible del espectro de estos pigmentos fotosintéticos. En el diagrama, la clorofila b absorbe fuertemente en las bandas azul (450 nm) y roja (670 nm), lo que se conoce como "bandas de absorción de clorofila". Esta absorción es la razón por la cual el ojo humano percibe la vegetación sana como verde, ya que la planta refleja principalmente luz verde mientras absorbe el azul y el rojo. Cuando la planta está sometida a estrés, su producción de clorofila disminuye, lo que reduce la absorción en las regiones azul y roja del espectro y aumenta la reflexión en la banda roja (Lillesand et al., 2015).




Figura 3.3 Diagrama tomado de Pareek et al. 2017 en donde se muestran las firmas espectrales de tres tipos de pigmentos, Carotenoides, Clorofila a y b.

En cuanto a la firma espectral de la vegetación, en la figura 3.2 se observa que al pasar la parte visible, la reflectancia de la vegetación aumenta drásticamente. Esta característica espectral es conocida como borde rojo el cual ya se había explicado anteriormente, la cual generalmente se presenta entre 680 y 750 nm, sin embargo, la longitud varía un poco y depende de la especie y la condición de la planta. Otra característica importante de la firma espectral es que entre las longitudes de onda 0.75 y 1.3 m que corresponde a una parte del NIR (Infrarrojo cercano), las plantas reflejan de 40 al 50 % de la energía incidente, por lo que en esta parte la absorción de la energía es mínima. También en el diagrama se pueden ver tres zonas de absorción en 1400, 1900 y 2700 nm, esto se debe a que el agua de la hoja absorbe fuertemente la energía en estas longitudes de onda, estas zonas se llaman bandas de absorción de agua.




Figura 3.4 Diagrama de reflectancia espectral del sargazo para cuatro estados diferentes Fresco, mixto seco y descompuesto. Figura tomada de Chandler et al. (2023).

En cuanto a las algas, al ser vegetación tienen comportamientos similares a las plantas por lo que sus características espectrales pueden ser utilizadas para detectar sargazo por vía

satelital. Sin embargo, hay algunas diferencias en estos comportamientos espectrales, Chandler et al., 2023 hacen un estudio donde compara los comportamientos espectrales del sargazo en diferentes estados del mismo: sargazo mojado o vivo, sargazo seco y la mezcla como se puede ver en la figura 3.4. El sargazo vivo exhibió una respuesta espectral distintiva con dos picos de reflectancia a 600 nm y 645 nm y un valle de reflectancia notable alrededor de 630 nm (es decir, clorofila C). Por otro lado, el sargazo seco mostró una alta reflectancia en las regiones del infrarrojo cercano y del infrarrojo de onda corta en comparación con el material mojado, la diferencia entre la reflectancia espectral del material descompuesto y el fresco fue menos pronunciada en la región del infrarrojo de onda corta, estas diferencias espectrales de los diversos estados del sargazo también pueden influenciar en los resultados obtenidos de detección a partir percepción remota.

3.2.2 Índices espectrales

Los índices son herramientas clave en la percepción remota y se han implementado ampliamente para evaluaciones cuantitativas y cualitativas de distintos tipos de coberturas, utilizando diversas plataformas aéreas y satelitales (Xue & Sue, 2017). En el ámbito marino, permiten identificar la presencia y el estado de la vegetación y otros elementos en el agua. En el caso del sargazo, estos índices son esenciales para su detección, ya que facilitan su diferenciación respecto a otros componentes marinos.

Los índices espectrales son ecuaciones que combinan los valores de los píxeles de dos o más bandas espectrales de una imagen multiespectral (Xue et al., 2017). Una banda espectral se refiere a una sección definida del espectro electromagnético que puede ser detectada por un sensor. Estos índices están diseñados para resaltar los píxeles que muestran la abundancia relativa o la ausencia de un tipo de cobertura terrestre de interés en una imagen.

En este trabajo, se utilizan el índice NDVI y el índice FAI, ya que ambos son particularmente útiles en el monitoreo del sargazo debido a su capacidad para distinguir la vegetación flotante del agua, una característica fundamental en la detección de algas como el sargazo. A continuación, se detallan y explican estos dos índices.

3.2.2.1 Índice de vegetación de diferencia normalizada (NDVI)

Uno de los índices más ampliamente utilizados para la evaluación de la vegetación es el Índice de Vegetación de Diferencia Normalizada (Rouse et al., 1973). Su popularidad se debe a que puede calcularse con cualquier sensor que detecte la reflectancia en la parte visible y el infrarrojo cercano del espectro electromagnético, este índice nos brinda información importante acerca de la vegetación y su crecimiento. En esta tesis se emplea para detectar algas flotantes como el sargazo. Su capacidad para diferenciar entre superficies altamente reflectivas, como el agua, y la vegetación, lo convierte en una herramienta útil para detectar la presencia de sargazo

La expresión matemática del NDVI es la relación entre la diferencia entre la banda del infrarrojo cercano (NIR) y la banda roja (R) y la suma de estas dos bandas (Rouse et al., 1973):

$$NDVI = (R_{NIR} - R_{RED}) / (R_{NIR} + R_{RED})$$

El intervalo de valores de este índice se encuentra entre -1 y +1. Valores positivos corresponden a zonas con vegetación; cuanto mayor sea el índice, mayor será el contenido de clorofila del objetivo, algunos ejemplos podrían ser cultivos, arbustos, pastos y bosques (Yengoh et al., 2015). En cambio, valores negativos corresponden a cuerpos de agua y valores cercanos a cero generalmente corresponden a rocas, arenas o superficies de concreto (Jones & Vaughan, 2010).

Este índice tiene como fundamento la interacción de las plantas con la luz solar. Y se utiliza principalmente para estudios relacionados con uso del suelo, caracterización y producción primaria, pero también se ha utilizado en estudios de algas (Hu, 2019; Hu et al., 2015). Sin embargo, el NDVI es sensible a los efectos del brillo del suelo, el color del suelo, la atmósfera, las nubes, la sombra de las nubes y del dosel de las hojas (Xue, 2017). Además, es sensible a las condiciones ambientales y de observación variables, como los aerosoles y la geometría solar de visualización (Hu, 2015), por lo cual debe usarse con consideración.

3.2.2.2 Índice de algas flotantes (FAI)

El índice FAI, fue creado por Hu en 2009, y fue desarrollado principalmente para utilizarse en imágenes provenientes de MODIS. Está basado en el principio de que, a diferencia de las superficies terrestres, el agua absorbe fuertemente la luz en las longitudes de onda RED, NIR y SWIR y que, por otro lado, las algas flotantes en el agua reflejan la luz en el infrarrojo cercano NIR más que en otras longitudes (Hu, 2009).

Matemáticamente se expresa como:

$$FAI = R_{rc,NIR} - R'_{rc,NIR}$$

$$R'_{rc,NIR} = R_{rc,RED} + (R_{rc,SWIR} - R_{rc,RED}) \times (\lambda_{NIR} - \lambda_{RED}) / (\lambda_{SWIR} - \lambda_{RED})$$

donde los subíndices NIR (Infrarrojo cercano), RED (Rojo) y SWIR (Infrarrojo de onda corta) representan las bandas espectrales y donde R_{rc} se refiere a la reflectancia en las bandas correspondientes después de la corrección de Rayleigh, la cual es una corrección que aplica Hu antes de calcular el índice, con el objetivo de eliminar la dispersión molecular Rayleigh.

Este índice ha demostrado ser más sólido que el NDVI tradicional en términos de respuesta a las perturbaciones de las condiciones ambientales, la geometría de visualización, el brillo del sol y la contaminación de nubes delgadas (Zhang et al., 2019). Además, a diferencia de NDVI el FAI está diseñado específicamente para detectar vegetación flotante, como el sargazo en el agua. Sin embargo, una desventaja es que el índice FAI no se puede extender a otros sensores satelitales que no estén equipados con una banda SWIR y que

además es muy sensible a aguas turbias y bajas profundidades y puede confundir las nubes, las olas y reflejos del sol con algas (Hu,2009).

3.5 Aprendizaje Automático (Machine Learning)

El Aprendizaje Automático, o Machine Learning en inglés, es una rama de la inteligencia artificial (IA) que permite construir modelos matemáticos capaces de aprender, identificar patrones y detectar tendencias en una base de datos, para luego realizar predicciones con datos nuevos (Hossain, 2024).

En el contexto del Aprendizaje Automático, cuando se usa el término "aprender" se refiere a la capacidad de un modelo para ajustar sus parámetros de manera que pueda aproximar una función subyacente, la cual describe la relación entre las variables de entrada (características) y las variables de salida (objetivos o etiquetas) en los datos (Yang & Shami, 2020). Lo que resulta ideal para detectar sargazo en fotografías de EVMC, ya que permite identificar patrones específicos en los píxeles de las imágenes, distinguiendo aquellos que pertenecen a sargazo de los que no, y así cuantificar los píxeles correspondientes. Esto facilita obtener una estimación de la cantidad de sargazo presente en cada fotografía. En el Aprendizaje Automático existen cuatro principales mecanismos de aprendizaje: supervisado, no supervisado, semi-supervisado y por refuerzo.

3.5.1 Aprendizaje supervisado.

El aprendizaje supervisado comprende aquellas técnicas que utilizan conjuntos de datos con características o etiquetas definidas. El aprendizaje supervisado puede dividirse en dos categorías: clasificación y regresión. En el caso de clasificación, la etiqueta es discreta mientras que en la regresión la etiqueta es continua (Nasteski, 2017).

Para comprender el aprendizaje supervisado en una tarea de clasificación, supongamos que se tiene un conjunto de datos $S = \{s_i = (X_i, Y_i)\}$ donde $i = 1, \dots, N$ con $N \in \mathbb{Z}$. Donde $X_i \in \mathbb{R}^M$ representa el i -ésimo vector de características predictoras y $Y_i \in \mathbb{Z}$ es la respuesta asociada al vector X_i , la cual se busca predecir.

El objetivo del aprendizaje supervisado es ajustar un modelo o función f que relacione las etiquetas Y_i con las características X_i , y así posteriormente predecir con precisión la etiqueta Y_i , en observaciones futuras x_{test} .

$$y = f(x_{test}) + \epsilon$$

En el contexto de esta tesis cada vector X_i contiene las características de un pixel, que son los niveles de rojo, verde, azul, matiz, saturación y brillo ($M = 6$). Así mismo, la variable de

respuesta Y_i , indica si el pixel asociado a X_i corresponde a sargazo ($Y_i = 1$) o no sargazo ($Y_i = 0$) en la imagen.

Utilizaré la notación $X_{i,j}$ con $i 1, \dots, N$; $j 1, \dots, M$ para denotar la j -ésima característica de i -ésima observación. Para ilustrar mejor esta estructura, en la Tabla 3.1 representa el conjunto de datos utilizado.

Tabla 3.1. Visualización en forma de tabla de un conjunto de datos, donde las x' son cada uno de los valores de las características y las y' son las etiquetas.

Observación	Rojo	Verde	Azul	Brillo	Matiz	Saturación	Etiqueta
X_1	$x_{1,1}$	$x_{1,2}$	$x_{1,3}$	$x_{1,4}$	$x_{1,5}$	$x_{1,6}$	y_1
.
.
X_n	$x_{n,1}$	$x_{n,2}$	$x_{n,3}$	$x_{n,4}$	$x_{n,5}$	$x_{n,6}$	y_n

3.5.1.1 El proceso de aprendizaje supervisado y sus métricas.

El proceso de aprendizaje de un modelo de aprendizaje supervisado se divide principalmente en 4 fases según Nasteski 2017: Recopilación de datos de entrenamiento, división de los datos, entrenamiento y prueba.

En la fase de división de los datos nuestro conjunto de datos se segmenta en dos partes distintas: conjunto de train (entrenamiento) y conjunto de test (prueba).

En el proceso de entrenamiento, se toma el conjunto de los datos de entrenamiento como entrada para que el algoritmo de aprendizaje encuentre los patrones en las características de los datos y que “aprenda” cómo clasificarlos. Así es como el algoritmo construye el modelo de aprendizaje (Nasteski, 2017).

Una vez completado este proceso, comienza la etapa de prueba, en la cual se utiliza el modelo de aprendizaje ajustado para realizar predicciones sobre el conjunto de datos de test. Estos datos son nuevos para el modelo, es decir, no han sido previamente "vistos" por el algoritmo, pero sus etiquetas son conocidas. Con base en los resultados obtenidos por el algoritmo, se evalúa su rendimiento.

Para una mejor evaluación del algoritmo, se puede utilizar el método llamado validación cruzada o cross validation en inglés. Este se lleva a cabo dividiendo todo el conjunto de datos en K grupos y los $K - 1$ grupos se usan para entrenar y el grupo restante K , se utiliza

para la evaluación: los grupos de datos (los K) se van cambiando hasta que todos los grupos se entrenan, finalmente se calcula un promedio del rendimiento (Bauer, 1998).

Para poder evaluar el rendimiento de nuestro algoritmo, se encuentran variedad de métricas diferentes. Para definir las, se construye una matriz de confusión. La cual se genera a partir de la diferencia entre los resultados obtenidos que obtengamos en la etapa de evaluación y los verdaderos (tabla 3.2). En ella se identifican dos tipos de errores: el error de tipo I, conocido como falso positivo (que es cuando el modelo predice una etiqueta positiva cuando en realidad no lo es), y el error de tipo II, conocido como falso negativo (el modelo no detecta correctamente un caso positivo y lo clasifica incorrectamente como negativo).

Tabla 3.2. Matriz de confusión con identificación de errores Tipo I y Tipo II.

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdaderos positivos (VP)	Falsos negativos (FN) Error tipo II
	Negativos	Falsos positivos (FP) Error tipo I	Verdaderos negativos (VN)

En cuanto a las métricas más utilizadas se encuentran la precisión, la recuperación, el accuracy (exactitud) y la puntuación F1 (Dalianis, 2018), en la tabla 3.3 se observan las fórmulas de cada una.

- La **precisión** se define matemáticamente como el número de verdaderos positivos dividido por la suma de los verdaderos positivos y los falsos positivos. En otras palabras, la precisión indica la proporción de instancias clasificadas como positivas que son realmente positivas, respecto al total de instancias clasificadas como positivas (tanto verdaderos positivos como falsos positivos).
- La **recuperación**, por su parte, se define como el número de verdaderos positivos dividido por la suma de los verdaderos positivos y los falsos negativos (que también son positivos, pero fueron clasificados incorrectamente). Esta métrica mide la proporción de instancias positivas que son correctamente identificadas por el modelo en relación con el total de instancias que son realmente positivas.
- La **exactitud** (también llamada *accuracy* en inglés) es otra medida que se calcula como la proporción de instancias correctamente clasificadas, tanto positivas como negativas, sobre el total de instancias (Dalianis, 2018). Es decir, la exactitud refleja cuántas veces un modelo realizó una predicción correcta en todo el conjunto de datos.

- Finalmente, la **puntuación F1** es una medida más compleja que las anteriores y resulta especialmente útil en conjuntos de datos desequilibrados (Sitarz, 2023). Se define como la media armónica entre la precisión y la recuperación. En la figura 3.6 se presenta un diagrama que ilustra esta métrica.

En la actualidad ya existen numerosos algoritmos de clasificación. Este trabajo se centra en los métodos relativamente maduros de Aprendizaje Automático que son Máquinas de Soporte Vectorial SVM, Árboles aleatorios (Random Forest) y Redes Neuronales Perceptrón Multicapa y para evaluar el rendimiento de cada uno de estos modelos se utilizan las métricas previamente descritas.

Tabla 3.3 Métricas más populares para medir la precisión en algoritmos de Aprendizaje Automático.

Métrica	Fórmula
Precisión	$Precisión = \frac{VP}{VP+FP}$
Recuperación (Recall)	$Recuperación = \frac{VP}{VP+FN}$
Puntuación F1	$F1 = 2 \cdot \frac{Precisión \cdot Recuperación}{Precisión + Recuperación}$
Exactitud (Accuracy)	$Exactitud = \frac{VP+VN}{VP+VN+FP+FN}$

3.5.1.2 Árboles de decisión binarios.

Un árbol de decisión es un modelo predictivo utilizado el cual divide el espacio de predicción (conjunto de datos) en regiones más pequeñas mediante decisiones binarias. El nodo raíz del árbol abarca todo el espacio predictor y es donde se inicia el proceso de clasificación (James et al., 2020). A partir de este nodo, el árbol progresa de manera recursiva a través de nodos intermedios, que se dividen en dos nodos descendientes, uno a la izquierda y otro a la derecha (figura 3.5). Estas divisiones se basan en condiciones de separación específicas. El proceso continúa hasta llegar a los nodos hoja o terminales, donde finalmente se predice una etiqueta (Cutler et al., 2012).

Para decidir qué umbral de decisión o condición a utilizar en cada uno de los nodos intermedios se utilizan diferentes métricas, las más famosas son: el índice de Gini y la Entropía (Information Gain) para árboles de decisión categóricos; o el Error Residual o Cuadrático Medio para árboles de regresión (James et al., 2020). En esta tesis vamos a profundizar en el índice de Gini.

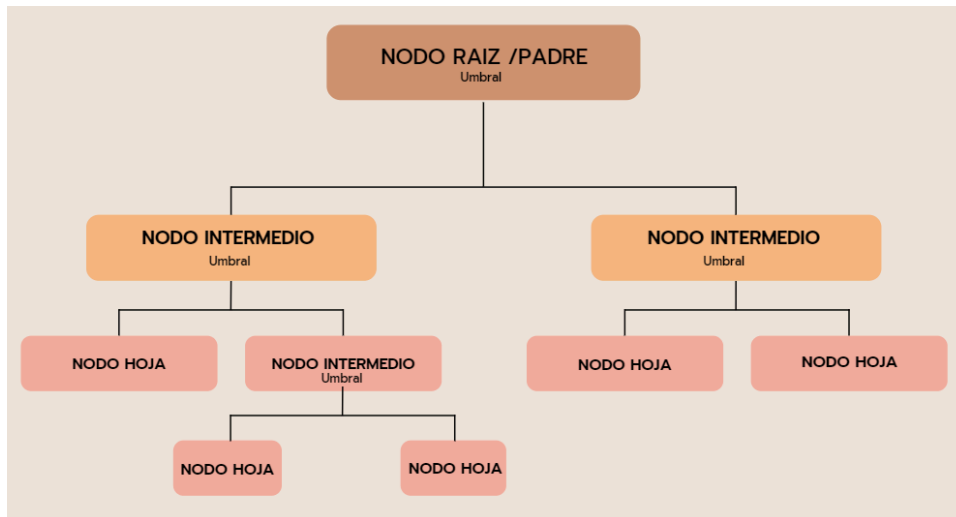


Figura 3.5 Diagrama de los tipos de nodos que conforman los árboles de decisión.

Índice de impureza de Gini o Índice GINI impurity

Como se mencionó anteriormente, los árboles de decisión binarios se construyen dividiendo repetidamente los datos en subconjuntos descendientes. Para lograr esto, es necesario seleccionar las divisiones de manera que los subconjuntos sean siempre más "puros" que sus predecesores, es decir cuando la mayoría (o todos) los elementos dentro de él pertenecen a la misma clase. Una de las métricas más utilizadas para guiar estas divisiones es el índice de impureza de Gini (Lovatti et al., 2019).

La impureza de Gini mide cuán mixto o impuro es un conjunto de datos. Para una división binaria, la impureza de Gini de un nodo q , la cual se denotarán por $G(q)$, se calcula de la siguiente manera:

$$G(q) = 1 - \sum_{k=1}^C p_k^2$$

Donde:

$p_k \in \mathbb{R}$ es la proporción de observaciones en el nodo q etiquetadas con la clase k ,

$C \in \mathbb{Z}$ es el número de clases posibles.

Sus valores oscilan entre 0 y 1. Un valor de 0 indica un conjunto de datos completamente puro, mientras que un valor de 1 representa un conjunto de datos totalmente impuro. Esto significa que, cuanto menor sea el índice Gini, más homogéneo será el conjunto de datos, y en consecuencia, mejor será la división en ese nodo del árbol.

El índice de Gini además de decidir la división óptima desde un nodo raíz y las divisiones posteriores. Puede utilizarse para asignar un rango de importancia a las características de un problema de clasificación (Lovatti et al., 2019). Esto se hace a partir de la reducción de impureza, la cual se define de la siguiente manera:

$$\text{Reducción de impureza} = Gini_{\text{padre}} - \left(\frac{N_{\text{hijo izq}}}{N_{\text{padre}}} \cdot Gini_{\text{hijo izq}} + \frac{N_{\text{hijo der}}}{N_{\text{padre}}} \cdot Gini_{\text{hijo der}} \right)$$

Donde:

- $Gini_{\text{padre}}$ es la impureza del nodo antes de la división
- $Gini_{\text{hijo izq}}$ $Gini_{\text{hijo der}}$ son las impurezas de los nodos hijos después de la división
- $N_{\text{hijo izq}}$ $N_{\text{hijo der}}$ son el número de observaciones en los nodos hijo izquierdo y derecho, respectivamente
- N_{padre} es el número total de observaciones en el nodo padre.

Para calcular la importancia de las características utilizadas para entrenar un modelo, se lleva a cabo el siguiente proceso:

- Se construye un árbol de decisión con nuestro conjunto de datos S
- Cada vez que el árbol toma una decisión y divide un nodo intermedio en dos, se calcula cuánto se ha reducido la impureza en esa división.
- Posteriormente se suman todos los valores de reducción de impureza para una característica y se calcula su promedio, dividiendo la suma de la reducción de impureza por el número total de nodos en los que esa característica fue utilizada para hacer divisiones (Raileanu y Stoffel, 2004).
- Las características se ordenan en función de su importancia, donde aquellas que contribuyen más a la reducción de la impureza de Gini tienen un ranking más alto.

3.5.1.3 Árboles aleatorios o Random Forest

Hasta la fecha, los árboles aleatorios, o Random Forest (RF) en inglés, se consideran uno de los algoritmos de clasificación más utilizados en estudios de percepción remota (Phan et al., 2020), y destacan por ser altamente eficientes en términos de precisión de predicción, velocidad y manejo de grandes volúmenes de datos (Cuevas et al., 2018) por lo que puede ser un algoritmo muy útil para la detección de sargazo.

La robustez de Random Forest radica en su enfoque como parte de los métodos de ensamble, que mejoran el rendimiento del modelo combinando múltiples algoritmos de aprendizaje; en este caso, varios árboles de decisión. Un problema con estos árboles, es su alta varianza, es decir, si los datos de entrenamiento se dividen aleatoriamente y se ajusta un árbol para cada subconjunto, los resultados pueden ser muy distintos entre sí. Esto significa que cada árbol podría interpretar los mismos datos de maneras diferentes, lo cual indica que no generaliza bien y podría fallar con datos nuevos (Hossain, 2024). Random Forest, al integrar múltiples árboles, atenúa esta varianza y crea un modelo más confiable y menos propenso al sobreajuste. Por lo que una forma natural de reducir la varianza y aumentar la precisión en un método de aprendizaje es tomar múltiples conjuntos de

entrenamiento de la población, construir un modelo de predicción utilizando cada conjunto de entrenamiento, y promediar las predicciones resultantes. Este proceso se denomina bagging, y es la clave que caracteriza al algoritmo Random Forest, lo que lo hace más poderoso en comparación con los árboles de decisión individuales. El método bagging consta de tres pasos principales:

1. **Bootstrap:** En este paso se generan múltiples conjuntos de datos de entrenamiento mediante la selección de subconjuntos de los datos originales con reemplazo. El objetivo es obtener una gran cantidad de subconjuntos de entrenamiento a partir de los datos disponibles.
2. **Entrenamiento:** Para cada subconjunto de datos, se entrena un modelo diferente que produce una predicción. Cabe destacar que no solo varían los datos en cada árbol, sino que también se utilizan diferentes subconjuntos de características en cada uno de ellos.
3. **Agregación:** Finalmente, una vez que todos los árboles han sido entrenados, se promedian sus predicciones para obtener el resultado final.

El proceso de Random Forest se puede visualizar en la figura 3.6, donde en vez de tener un solo árbol, se tienen 3, los cuales están entrenados a partir de diferentes subconjuntos de datos y características. Al final cada uno de los datos genera una predicción, la cual se va a someter a una votación y la etiqueta con más votos será la ganadora.

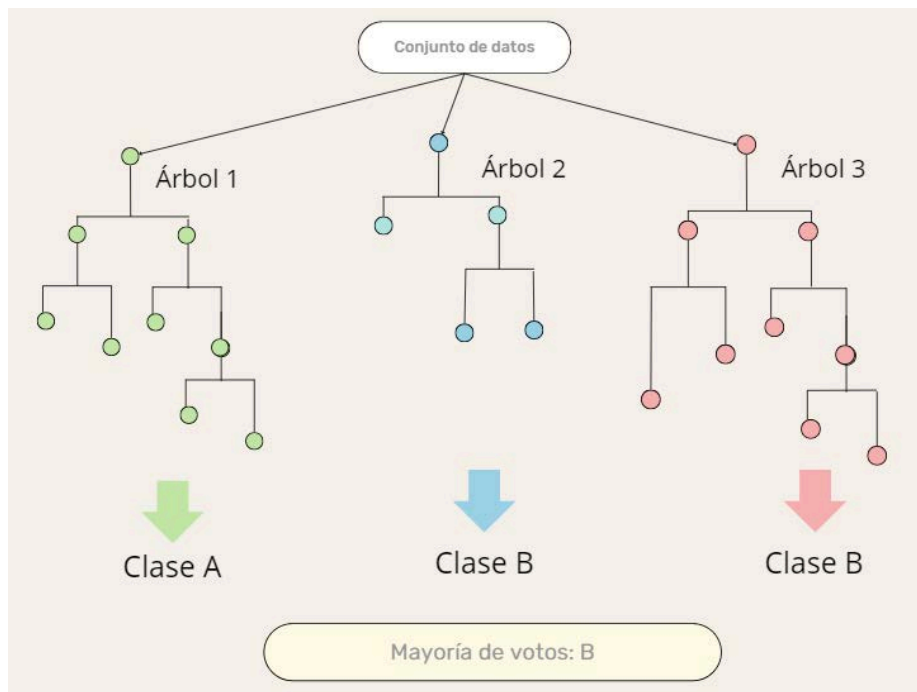


Figura 3.6 Diagrama que ilustra el método Bagging.

3.5.1.2 Máquinas de Soporte Vectorial (SVM)

El algoritmo Máquinas de soporte vectorial o Support Vector Machine en inglés (SVM) fue introducido primeramente en la década de los 70s, actualmente es uno de los algoritmos

más utilizados en la literatura (Sheykhmousa, 2020). Es un algoritmo que puede utilizarse en problemas de clasificación y de regresión. En este trabajo, se enfoca en el problema de clasificación, ya que es el que resulta relevante para esta tesis.

Básicamente cuando se utiliza SVM para clasificar, lo que hace el algoritmo es intentar encontrar un límite de decisión entre los datos, para así separarlos en diferentes clases, este límite de decisión se llama hiperplano separador.

En un espacio con dimensión p un hiperplano es un subespacio con una dimensión $p - 1$, por lo tanto, en dos dimensiones un hiperplano es un subespacio de una dimensión es decir una línea, en un espacio de tres dimensiones un hiperplano es un subespacio de dos dimensiones es decir un plano.

Un hiperplano Π en un espacio de dimensión $n \in \mathbb{Z}$ se define como el conjunto de vectores $X=(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ que satisfacen la siguiente ecuación:

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = 0,$$

donde $\beta_i \in \mathbb{R}, i = 1, \dots, n$, son los coeficientes asociados a cada variable predictora.

Si existe un hiperplano separador, este puede utilizarse para construir un clasificador lineal. La asignación de clases a una observación X_i se realiza en función de la posición de X_i con respecto al hiperplano, i.e.,

Si

$$\beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \dots + \beta_n X_{i,n} < 0,$$

entonces se asigna la etiqueta $y_i = 0$.

Análogamente, si

$$\beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \dots + \beta_n X_{i,n} > 0 \text{ si } y_i = 1,$$

entonces se asigna la etiqueta $y_i = 1$.

En la figura 3.7b se observan los elementos del SVM en dos dimensiones: el hiperplano positivo y negativo, así como también el hiperplano y el margen máximos. Este último se define como la distancia perpendicular desde el hiperplano hasta los vectores de soporte que son puntos más cercanos al hiperplano.

En general, si los datos son linealmente separables, existe un número infinito de hiperplanos que pueden separar las clases figura 3.7a. Esto se debe a que un hiperplano separador puede desplazarse o rotarse ligeramente sin cruzar ninguna observación. Para identificar el mejor hiperplano, utilizamos el hiperplano de margen máximo (también llamado hiperplano de separación óptimo), que es aquel que maximiza la distancia mínima entre las

observaciones de entrenamiento y el hiperplano. Esta distancia mínima se conoce como margen, y las observaciones más cercanas al hiperplano son los vectores de soporte.

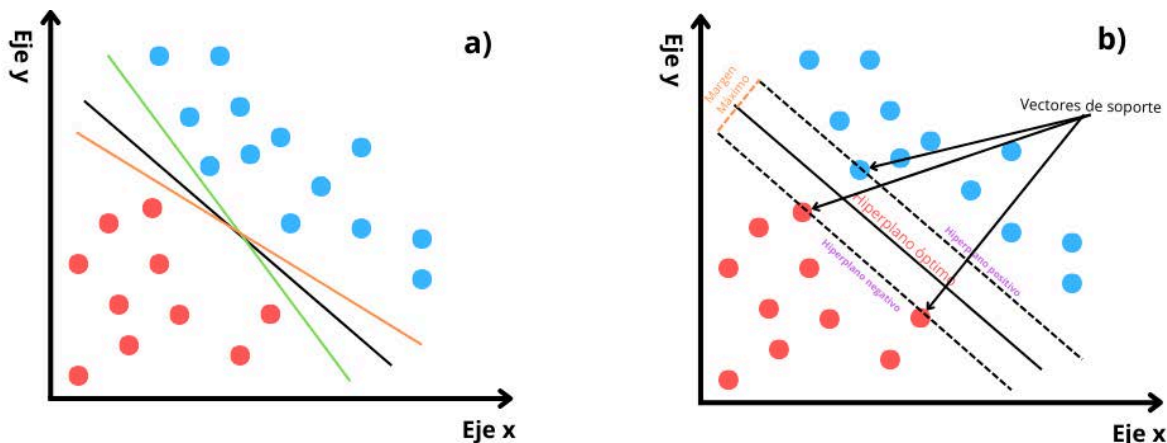


Figura 3.7 Diagramas de a) Dos clases de observaciones se muestran en el gráfico mostradas como puntos azules y rojos, también se muestran posibles planos que las dividen b) Imagen con los elementos del SVM: Hiperplano óptimo, positivo, negativo, el margen máximo y los vectores de soporte.

El hiperplano de margen máximo es aquel para el cual el margen es el más grande posible, es decir, el hiperplano que está más alejado de los vectores de soporte. Una vez encontrado, clasificamos una observación de prueba según el lado del hiperplano en el que se encuentre. Este enfoque se conoce como clasificador de margen máximo. Se espera que un clasificador con un margen grande en los datos de entrenamiento generalice bien a los datos de prueba, aunque en casos con un número elevado de características (p), puede ocurrir sobreajuste.

En resumen el objetivo de SVM es encontrar un hiperplano que separe las clases con el mayor margen posible. Este problema se resuelve mediante técnicas de optimización, y para datos no linealmente separables, se extiende utilizando funciones de kernel.

3.5.1.2.1 El truco de Kernels en SVM

Cuando los datos son linealmente separables, un SVM lineal es suficiente para encontrar el hiperplano que divide las diferentes clases. Sin embargo, en muchos casos, los datos no son linealmente separables en su espacio de dimensiones original. En estas situaciones, es necesario utilizar el truco del kernel. Este truco permite encontrar hiperplanos que separan las clases sin la necesidad de transformar explícitamente los datos a un espacio de dimensiones superiores. Esto es posible porque el SVM no necesita trabajar directamente en el espacio de dimensiones superiores durante el entrenamiento o la prueba.

En lugar de ello, se utilizan funciones kernel, que son funciones matemáticas que, dados dos vectores v y $w \in \mathbb{R}^n$ calculan implícitamente el producto punto entre v y w en un espacio de dimensiones superiores \mathbb{R}^M , sin transformar explícitamente los vectores a \mathbb{R}^M . Estas funciones permiten que el SVM opere eficientemente, ya que trabajan directamente con los

datos en su espacio original, pero imitan el comportamiento del producto punto en el espacio transformado (Kim, E., 2013).

En otras palabras, cuando se usa el Kernel podemos encontrar los hiperplanos que dividan las clases, en espacios donde estos datos si sean separables, sin necesidad de transformar todos los datos a estos nuevos espacios. Algunas de las funciones de kernel más famosas son el kernel RBF y el kernel polinomial.

- *El kernel Función de base radial o RBF Radial Basis Function*

El kernel gaussiano, también llamado Radial Basis Function (RBF), es un kernel que tiene la forma de una función de base radial o gaussiana.

Para poder entender este concepto consideremos el conjunto de datos de entrenamiento $S = \{s_i = (X_i, Y_i)\}$ con $X_i \in \mathbb{R}^M$. El Kernel RBF para dos puntos $X_i \in \mathbb{R}^M$ y $X_{i'} \in \mathbb{R}^M$, $i = 1, \dots, n; i' = 1, \dots, N$ se define como:

$$k(X_i, X_{i'}) = \exp\left(-\frac{\|X_i - X_{i'}\|^2}{2\sigma^2}\right)$$

- Donde $\|X_i - X_{i'}\|^2$ es la norma euclidiana entre los puntos X_i y $X_{i'}$,
- $\sigma \in \mathbb{R}$ es un parámetro que controla el ancho del kernel.

A menudo, se introduce un cambio de variable γ definido como $\gamma = \frac{1}{2\sigma^2}$, lo que permite reescribir la ecuación de la siguiente manera:

$$k(x_1, x_2) = \exp(-\gamma \|X_i - X_{i'}\|^2)$$

Este kernel, calcula una nueva representación de los datos basada en distancias entre puntos, donde se mide qué tan similares son dos puntos y convierte la distancia en un valor entre 0 y 1 (Kuo et al., 2014). El valor máximo que puede tener el núcleo RBF es 1 y ocurre cuando $\|X_1 - X_{i'}\|^2$ es 0, que es cuando los puntos son iguales ($X_i = X_{i'}$), por lo tanto, no hay distancia entre ellos y por lo tanto son sumamente similares.

Con el parámetro γ puedes controlar qué tan "estricto" o "flexible" es el modelo para clasificar los datos y puede interpretarse como el ancho de la curva de la campana del kernel. Cuanto mayor sea el valor de γ , más estrecha será la campana de la distribución, y cuanto menor sea, la campana será más ancha (Kuo et al., 2014). Un valor más alto de γ en el kernel RBF aumenta la sensibilidad a las distancias entre los puntos, lo que resulta en una ponderación más fuerte de los puntos cercanos. Esto puede llevar a un límite de decisión más complejo y ajustado, aumentando el riesgo de sobreajuste. En la figura 3.8 se ilustran dos casos: en azul, un valor pequeño de γ genera una campana ancha, lo que significa que la influencia de los puntos cercanos se extiende sobre un rango más amplio.

En rojo, un valor grande de γ produce una campana más estrecha, lo que implica que solo los puntos muy cercanos tienen una influencia significativa en la predicción.

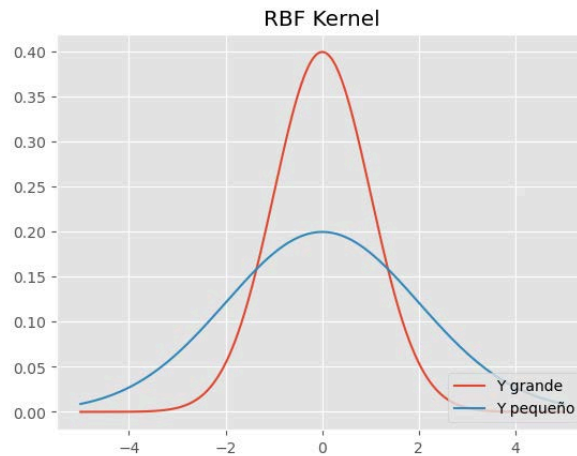


Figura 3.8 Diagramas de los valores diferentes del parámetro γ de la función de kernel radial.

Elegir un valor adecuado de γ es crucial, ya que un valor demasiado alto puede llevar al modelo a memorizar los datos de entrenamiento (*overfitting*), mientras que un valor demasiado bajo puede hacer que el modelo no capture adecuadamente la estructura de los datos (*underfitting*).

- *Kernel polinomial*

Al igual que el kernel radial, el kernel polinomial permite encontrar un hiperplano en un espacio de características de mayor dimensión. El kernel polinomial se define como:

$$K(X_i, X_{i'}) = (X_i \cdot X_{i'} + c)^n$$

donde $X_i \in \mathbb{R}^M$ y $X_{i'} \in \mathbb{R}^M$, $i = 1, \dots, n$; $i' = 1, \dots, N$, son los vectores de características, $n \in \mathbb{Z}$ es la dimensión del kernel y c es un término de sesgo (bias), que permite controlar la flexibilidad del modelo.

Este kernel permite modelar relaciones no lineales entre los datos, ya que eleva el producto escalar a una potencia n , lo que equivale a mapear los datos a un espacio de dimensión mayor sin necesidad de calcular explícitamente todas las nuevas características. Lo que también conduce a un límite de decisión mucho más flexible. Básicamente, equivale a ajustar un clasificador de vectores de soporte en un espacio de dimensiones superiores que involucra polinomios de grado d , en lugar de en el espacio de características originales (Hastie, 2009).

La dimensión elegida controla la flexibilidad del límite de decisión. Pero es importante tomar en cuenta que valores más altos de dimensión pueden resultar en límites de decisión más flexibles, pero también pueden aumentar el riesgo de sobreajuste (Hastie, 2009).

3.5.1.3 Redes neuronales

En las últimas décadas, las redes neuronales han ganado popularidad en el campo de la percepción remota, impulsadas en parte por la abundancia de datos obtenidos a través de sensores remotos (Atkinson, 1997). Estas redes se inspiran en el funcionamiento del cerebro humano, donde las neuronas reciben entradas de otras neuronas y producen salidas que se transmiten a través de conexiones neuronales (Atkinson, 1997). Aunque las redes neuronales intentan emular este proceso mediante un enfoque matemático, es importante reconocer que no se busca ni es posible reproducir la complejidad total del cerebro humano en un entorno computacional (Atkinson, 1997).

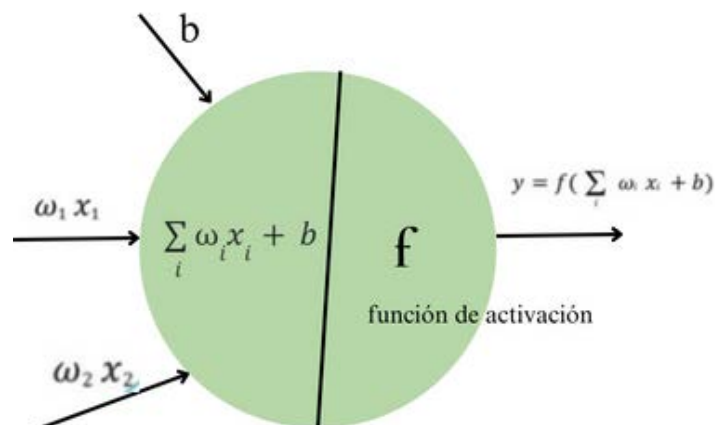


Figura 3.9 Ilustración de la estructura de una neurona usada en redes neuronales.

Matemáticamente la idea central de las redes neuronales es calcular combinaciones lineales de las variables predictivas para generar características combinadas. Posteriormente, este resultado se transforma mediante una función no lineal lo que genera un potente método de aprendizaje (Hastie, 2009).

Hay diferentes tipos de arquitecturas redes neuronales tales como: convolucionales, generativas entre otras. Sin embargo, este capítulo se enfoca en el perceptrón multicapa o Multi Layer Perceptron (MLP), la cual es una de las arquitecturas más simples y comunes de redes neuronales artificiales.

Para comprender la red neuronal MLP, es fundamental comenzar con la comprensión del perceptrón, el cual es un clasificador binario fundamental en el aprendizaje automático (figura 3.9). Este tipo de clasificador consta de dos partes, una suma ponderada en la cual se asignan importancias relativas a las variables predictivas, y una función de activación, la cual es una función no lineal.

En un perceptrón cada una de las M características predictoras en X_i se le asocia un peso $w_j \in \mathbb{R}$; $j = 1, 2, \dots, M$, cuyo efecto es reflejar su importancia en la decisión. Estos pesos son usados para calcular una suma ponderada:

$$z = \sum_{j=1}^M w_j * X_{i,j} + b$$

donde b que representa el sesgo bias.

Finalmente, al valor resultante z se le aplica la función de umbral $f(z): \mathbb{R} \rightarrow \{0, 1\}$ usualmente llamada de activación, cuyo efecto es asignar una clasificación al vector X_i dado el vector de pesos w_j i.e.,

$$f = f\left(\sum_{i=1}^n w_i X_i + b\right)$$

Una función de activación f toma un valor z (que es la suma ponderada de las entradas más el sesgo) y produce una salida. Hay diferentes funciones populares de activación, normalmente las más utilizadas son:

Sigmoide: Es la misma función utilizada en la regresión logística para convertir una función lineal en probabilidades entre cero y uno. Convierte los valores en 0 para valores muy negativos y en 1 para valores muy positivos. En redes neuronales sirve para garantizar que los valores no sean extremadamente altos o bajos (Hastie, 2009). Se expresa de la siguiente forma:

$$f(z) = \frac{e^z}{1+e^z} + \frac{1}{1+e^{-z}}$$

ReLU: Esta función significa Unidad Lineal Rectificada y básicamente consiste en una función de identidad ($y = x$) cuando $x \geq 0$ y se convierte en 0 cuando $x < 0$. Esta función de activación es muy utilizada en el entrenamiento de redes neuronales al ser una función no lineal y simple (Hossain, 2023). Se expresa de la siguiente manera:

$$f(z) = (z)_+ = 0 \text{ si } z < 0$$

$$f(z) = (z)_+ = z \text{ si } z > 0$$

El objetivo del perceptrón es predecir una salida en función de los pesos y los valores de sesgo. Por lo tanto, los pesos y los valores de sesgo son los valores que deben ajustarse en función de los datos existentes para así crear nuestro modelo óptimo, a esto se le llama la etapa de entrenamiento de una red neuronal.

En la figura 3.10 se ilustran dos funciones de activación graficadas, en rojo se observa la función sigmoide y en azul la función ReLU.




Figura 3.10 Gráfica de dos funciones de activación comúnmente utilizadas en rojo se muestra la función sigmoide y en azul ReLU.

3.5.1.3.1 Red neuronal Artificial Perceptrón Multicapa

Como se ha mencionado anteriormente, un perceptrón es uno de los elementos fundamentales de las redes neuronales y está conformado por pesos y una función de activación. Sin embargo, existe una extensión de este algoritmo llamado Red neuronal Artificial (RNA) Perceptrón Multicapa o MLP por sus siglas en inglés de Multi Layer Perceptron que a diferencia del perceptrón simple, que tiene solo una capa de neuronas (la capa de salida), el Perceptrón Multicapa tiene múltiples capas de neuronas, que permiten la modelización de problemas más complejos. En la figura 3.11 se muestran los elementos de una RNA MLP que son: la capa de entrada, las capas ocultas y la capa de salida.

Durante el entrenamiento de una red MLP, todos los pesos deben ajustarse de manera que minimicen la diferencia entre las etiquetas de salida generadas por la red y las etiquetas de referencia. Para lograr esto, se utiliza una función de pérdida J , que representa la interacción entre múltiples pesos y funciones de activación. Su cálculo requiere la aplicación de la regla de la cadena, ya que implica derivadas dependientes de funciones sigmoidales en cada capa (Hossain, 2023).

Este proceso de cálculo del gradiente de la función de pérdida mediante la regla de la cadena se conoce como Backpropagation o propagación hacia atrás (Rumelhart, 2013). Sin embargo, Backpropagation solo se encarga de calcular los gradientes, mientras que la actualización de los pesos se realiza a través de optimizadores. Aunque existen diversos algoritmos de optimización avanzados, el método más común sigue siendo el descenso de gradiente estocástico (Stochastic Gradient Descent, SGD) y sus variantes, como AdaGrad, Adam y RMSProp (Rumelhart, 2013), los cuales básicamente ajustan los pesos del modelo para minimizar la función de pérdida y mejorar el desempeño del aprendizaje.

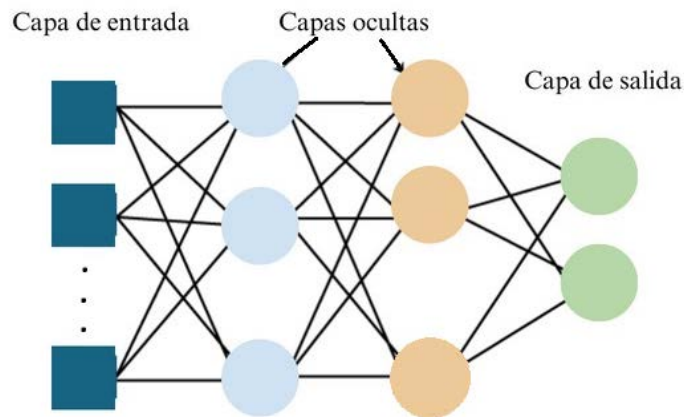


Figura 3.11 Arquitectura de una red neuronal con su capa de entrada, capa de salida y dos capas ocultas.

Entonces, para resumir, una red neuronal artificial MLP calcula combinaciones lineales diferentes de X , y luego aplasta cada una a través de una función de activación que la transforma. La no linealidad en la función de activación $f(z)$ es esencial, ya que sin ella nuestro modelo terminaría siendo un modelo lineal simple, sin embargo la función activación permite que el modelo se ajuste a problemas más complejos no lineales. En el entrenamiento la entrada X pasa a través de la red, y se obtiene una predicción, a partir de esta predicción se calcula un valor de pérdida (que es la diferencia entre la predicción y el valor real), se calculan los gradientes de la pérdida con respecto a cada peso con backpropagation y finalmente un optimizador usa los gradientes para actualizar los pesos.

3.5.2 Aprendizaje no supervisado

En el aprendizaje no supervisado, el conjunto de datos que se utiliza para entrenar los algoritmos es una colección de datos que no se encuentran etiquetados $(X_i)^n$. Siguiendo nuestro ejemplo de la tabla 3.1 es como si se tuvieran las características de Rojo, Verde, Azul y Brillo, pero sin tener una etiqueta asignada a cada una de las observaciones, por lo tanto, estos modelos deben encontrar relaciones y/o patrones entre las observaciones y variables para formar los distintos grupos. Es decir que el objetivo de este aprendizaje es crear un modelo a partir de las x_i y convertirlo en un vector o un valor que pueda ser utilizado para resolver algún problema (James et al., 2020). En este trabajo vamos a mencionar el Método K-means

3.5.2.1 Algoritmo K-means

La agrupación de K-means es un método de Aprendizaje Automático para encontrar clusters (grupos o conglomerados) de un conjunto de datos sin etiquetar (Hastie, 2009). El único parámetro que debe ser introducido para utilizar este algoritmo es el número de grupos (k) (Hossain, 2023).

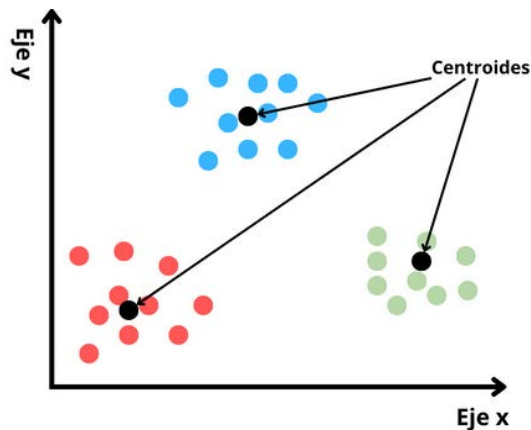


Figura 3.12 Ejemplo de tres clases diferentes agrupadas con el algoritmo K-means.

Para comenzar a utilizar K-means, se debe elegir el número deseado de grupos (K). El algoritmo de K-means opera moviendo iterativamente los centroides para minimizar la varianza total dentro de cada clúster. En K-means, los centroides son puntos en el espacio de características que representan la ubicación media de los datos en cada clúster (ver figura 3.12). El proceso se desarrolla de la siguiente manera:

- El algoritmo primero selecciona unos centroides aleatorios. Posteriormente a cada punto se le asigna el clúster cuyo centroide tiene la menor distancia euclidiana a este.
- Una vez que todos los puntos de datos han sido asignados a un clúster, los centroides se actualizan recalculando el centroide de cada clúster como la media de todos los puntos de datos asignados a ese clúster.
- Este proceso se repite hasta que el modelo converja.

Seleccionar el valor adecuado de K es crucial para el rendimiento del algoritmo. Algunas técnicas comunes para determinarla incluyen:

3.5.2.1.1 Método del codo

El método del codo es una técnica utilizada para determinar el número óptimo de grupos (clusters) en el algoritmo de K-means. El objetivo de K-means es agrupar datos de tal manera que los puntos dentro de un grupo sean lo más similares entre sí posible, mientras que los puntos en diferentes grupos sean lo más diferentes posible.

Es uno de los métodos más utilizados (Kodinariya, 2013) y funciona a partir de un concepto llamado distorsión, la cual se define como la suma de las distancias al cuadrado de cada punto al centroide más cercano. Su ecuación se ve de la siguiente manera:

$$D = \sum_{j=1}^k \sum_{i=1}^n \left\| x_i^j - c_j \right\|^2$$

Donde:

k es el número de clusters

n es el número de casos

x_i es el caso i

c_j es el centroide j

La distorsión en el contexto de K-means indica qué tan compactos y bien definidos son los clústers. Este valor disminuye conforme aumenta el número de clústers y alcanza su mínimo teórico de cero cuando cada punto forma su propio clúster.

Para encontrar un número adecuado de clústeres, se emplea frecuentemente el método del codo, el que se inicia calculando la distorsión con $K = 2$ y se incrementa gradualmente, calculando el valor de la distorsión para cada valor de K . Luego, se grafica el número de clústeres (K), en el eje x y la distorsión en el eje y. Si la gráfica toma la forma de un brazo doblado, el "codo" indica el punto donde la reducción en la distorsión comienza a ser menos pronunciada. Este codo se considera el valor óptimo de K , ya que equilibra la compactación de los clústeres sin generar un número excesivo de grupos (Pandey et al., 2018).

3.5.2.1.2 Gráfico de silueta

El gráfico de silueta es una técnica utilizada para evaluar la calidad de los grupos (clusters) creados por un algoritmo de agrupamiento, como K-means o clustering jerárquico. Este gráfico ayuda a determinar cuán bien están separados los diferentes clusters y cuán compactos son, ofreciendo una visualización del grado de cohesión y separación entre los grupos (Taleby et al., 2020) en este trabajo se utilizó para complementar la prueba de codo.

Para generar este gráfico, se debe calcular el coeficiente de silueta, éste tiene que ver con la diferencia entre la distancia que tiene un punto a otros puntos en el mismo grupo y la distancia que tiene a otros puntos en otros grupos, los valores del coeficiente de silueta van entre 0 y 1 y se calcula de la siguiente manera:

$$s(o) = \frac{b(o) - a(o)}{\max\{a(o), b(o)\}}$$

Donde:

- $s(o)$ es el coeficiente de silueta del punto o
- $a(o)$ es la distancia promedio entre o y todos los demás puntos en el grupo al que pertenece o
- $b(o)$ es la distancia promedio mínima desde o a todos los grupos a los que o no pertenece

Es decir, $a(o)$ es una longitud promedio de todas las líneas dentro del cluster A (líneas rojas de la figura 3.14). y si se consideran otros dos grupos por ejemplo C y D los cuales son diferentes de A, se calcula $b(o)$, que indica la longitud promedio mínima de todas las líneas que van desde x_i (en el grupo A) a C o D. En el ejemplo de la figura 3.13 la longitud promedio mínima es de A a C.

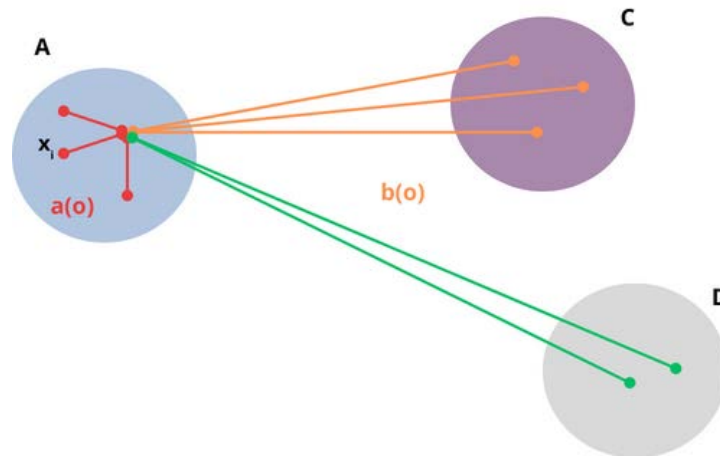


Figura 3.13 Ilustración que ejemplifica los dos tipos de distancias que se necesitan para calcular el coeficiente de silueta.

El coeficiente de silueta ofrece una medida sobre la calidad de la clasificación de los puntos dentro de los grupos. Una puntuación de 1 indica que un punto está integrado en su grupo y se encuentra lejos de los otros grupos, lo que sugiere una buena clasificación. En contraste, un valor de -1 señala una probable mala clasificación, ya que el punto podría estar en el grupo incorrecto. Los valores cercanos a 0 denotan superposición entre los grupos. Así, la prueba de silueta evalúa cuán adecuadamente se han agrupado los datos, considerando tanto la densidad interna de los clústeres como la distancia entre ellos (Shahapure, 2020).

Para visualizar esta métrica, se utiliza una gráfica de barras horizontales, donde la longitud de cada barra representa el valor del coeficiente de silueta de cada punto.

3.5.3 Aprendizaje semi-supervisado

En este tipo de aprendizaje el conjunto de datos contiene ejemplos de datos etiquetados y no etiquetados. Usualmente, contiene una mayor cantidad de datos no etiquetados que etiquetados. El objetivo de un algoritmo de aprendizaje semi-supervisado es el mismo que el objetivo del algoritmo de aprendizaje supervisado. Lo que se espera es que el uso de muchos ejemplos sin etiquetar pueda ayudar al algoritmo de aprendizaje a encontrar un mejor modelo (Sullivan, 2022).

3.5.4 Aprendizaje por refuerzo

El aprendizaje por refuerzo es un método en el que una computadora aprende a alcanzar un objetivo mediante interacciones de prueba y error con su entorno (Harmon, 1996). En otras palabras, los algoritmos de aprendizaje por refuerzo mejoran su desempeño a través de la experiencia, ajustando sus acciones en función de los resultados obtenidos (Hasselt, 2011).

Este método se basa en un agente que recibe una señal de refuerzo, representada por una recompensa numérica que indica el éxito de una acción. A partir de esta retroalimentación, el agente aprende a seleccionar aquellas acciones que maximicen la recompensa acumulada a lo largo del tiempo (Woergoetter et al., 2008).

El aprendizaje por refuerzo se diferencia del aprendizaje supervisado en que, en el aprendizaje supervisado los datos de entrenamiento tienen la clave de respuestas, por lo que el modelo se entrena con la respuesta correcta, mientras que en el aprendizaje por refuerzo no hay respuesta, pero el agente de refuerzo decide qué hacer (Sullivan, 2022).

3.6 Espacios de color

En las secciones anteriores se describieron los modelos de Aprendizaje Automático y se mencionó que, en esta tesis, se emplean algoritmos de aprendizaje supervisado para detectar el sargazo. Para entrenar estos algoritmos, es necesario contar con un conjunto de características y etiquetas. En el presente estudio, se optó por utilizar dos espacios de color diferentes como características para la detección del sargazo: el espacio de color RGB y el HSV.

Un espacio o modelo de color es un modelo matemático abstracto en el que los colores se representan como números, ya sea de tres o cuatro valores (Hema et al., 2020). Cuando el modelo de color está asociado con una descripción precisa o tiene asociada una función de mapeo esto resulta en un "espacio de color". El espacio de color también puede describir las formas en que se puede modelar la visión humana del color. En este trabajo se utilizaron dos espacios de color:

- **RGB:** Es llamado así por sus siglas en inglés Red, Green y Blue (rojo, verde y azul). En este espacio, los colores se representan como combinaciones de los componentes rojo, verde y azul en donde cada píxel de una imagen tendrá una capa roja, una capa azul y una capa verde que dará como resultado una imagen RGB. En el modelo RGB cada componente tiene un valor que va desde 0 hasta 255. Por ejemplo, cuando los tres canales de color tienen un valor de cero, significa que no se emite luz y, por lo tanto, el color resultante es negro. Cuando los tres canales de color están configurados en sus valores máximos, es decir 255, el color resultante es el blanco (Hema et al., 2020).

- **HSV:** Es considerado como el espacio más cercano a como los humanos describen las sensaciones de color y perciben los colores (Hema et al., 2020). Está conformado por:

Hue (matiz): representa el tipo de color, como rojo, verde o azul, con todos los matices intermedios que podemos percibir. Se mide en grados en un círculo de colores (0 a 360) (Hassan et al., 2017).

Saturation (saturación): se refiere a la pureza del color. Un valor alto significa que el color es más puro, mientras que un valor bajo tiende hacia el gris.

Value (valor o brillo): indica la luminosidad del color. Un valor alto significa que el color es más brillante, mientras que un valor bajo tiende hacia el negro.

Se puede representar geoméricamente en un cono, donde la base corresponde a H y se mide en grados, el eje horizontal la saturación, mientras que el eje vertical o altura corresponde al brillo del color, tal como se muestra en la figura 3.14.




Figura 3.14 Representación del espacio de color HSV en forma de cono. Hue (H) se mide en grados (0°-360°), Value (V) corresponde a la altura y Saturación (S) aumenta radialmente hacia el borde del cono.

Es relevante conocer estos espacios de color ya que las diferencias de valores en cada uno de los elementos de estos espacios permiten diferenciar los diferentes elementos en una imagen, en este caso son esenciales para diferenciar entre el sargazo y sus elementos circundantes como la arena, el agua y la vegetación etc. El espacio de color RGB, facilita la separación basada en la intensidad de cada canal. Por otro lado, el espacio HSV permite una distinción más precisa de colores similares, algo particularmente útil en ambientes complejos como el agua, donde no es tan contrastante la diferencia entre el agua y el sargazo comparado al sargazo en la arena.

4. ZONA DE ESTUDIO

El estudio se llevó a cabo en una sección de playa perteneciente a la Unidad Académica de Sistemas Arrecifales de la Universidad Nacional Autónoma de México (20.8686193 N, -86.8682847 E), ubicada en el municipio de Puerto Morelos, Quintana Roo. Este municipio, de reciente creación, fue oficialmente establecido el 6 de enero de 2016 y se localiza en la zona norte del estado, a 36 kilómetros de la península de Yucatán y al sur de Cancún. La región se asienta sobre una amplia plataforma de piedra caliza, producto de la deposición de carbonatos y evaporitas del Holoceno terciario sobre estratos del Jurásico-Cretácico (Ward et al., 1985). El clima es tropical, con dos estaciones principales: invierno y verano. Durante el invierno, que abarca de noviembre a marzo o abril, las temperaturas promedio varían entre 24 y 25 °C, mientras que en verano alcanzan los 29 °C, con máximas que superan los 34.5 °C (Coronado et al., 2007).

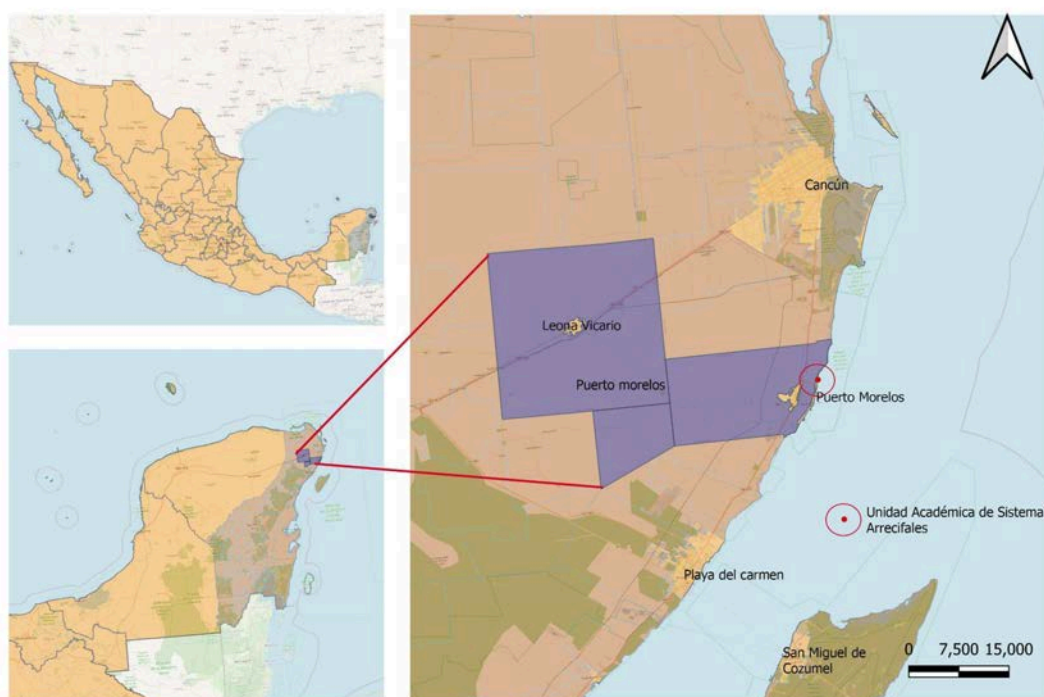


Figura 4.1 Mapa que muestra la zona de estudio.

Esta área ha sido afectada por las llegadas de las masas de sargazo, las cuales son transportadas principalmente por la Corriente de Yucatán, una ramificación importante de la Corriente del Caribe (Candela et al., 2003). Además, el régimen de vientos juega un papel crucial en el arribo del sargazo, favoreciendo su llegada durante la primavera y el verano (García-Sánchez et al., 2020).

En la figura 4.1, se muestra el municipio de Puerto Morelos en color morado, y en rojo se señala la ubicación de la Unidad Académica de Sistemas Arrecifales, donde se llevó a cabo este estudio. También se destacan algunos de los lugares aledaños famosos aledaños tales como Cancún y Playa del Carmen.

La economía de Puerto Morelos depende principalmente del turismo, el comercio y el sector inmobiliario (Marin et al., 2022). Solo en 2021, atrajo cerca de 15 millones de turistas, generando aproximadamente 10,807 millones de dólares (Rodríguez-Martínez et al., 2011). Sin embargo, la llegada masiva de sargazo ha afectado gravemente su atractivo turístico, dañando sus aguas y ecosistemas costeros, y posicionando a Puerto Morelos entre los 11 municipios más perjudicados del Caribe por este fenómeno (Rodríguez-Martínez et al., 2011). Esta situación resalta la importancia de estudiar esta zona, dada su vulnerabilidad frente a la problemática del sargazo.

5. DESCRIPCIÓN DE LOS DATOS

En este estudio se utilizaron dos tipos principales de datos: primeramente, fotografías obtenidas de una EVMC para detectar sargazo aplicando diferentes técnicas de aprendizaje automático. Así como también imágenes satelitales, esto con el objetivo de comparar y analizar ambos métodos de detección. Las imágenes satelitales proporcionan información sobre el sargazo en grandes áreas oceánicas, mientras que las fotografías capturan detalles específicos de las playas, permitiendo un análisis más local y detallado.

5.1 Fotografías de las estaciones de video monitoreo

En septiembre de 2015, el Dr. Tonatiuh Mendoza, a través del Laboratorio de Ingeniería y Procesos Costeros de la Unidad Académica Sisal del Instituto de Ingeniería de la UNAM, instalaron dos cámaras stingray 125 Cmca Allied Vision, las cuales están ubicadas a 15 metros de altura aproximadamente 50 metros de la línea costera en la unidad del Instituto de Ciencias del Mar y Limnología de la UNAM. Esta estación utiliza el sistema de monitoreo SIRENA, el cual permite la obtención de fotografías diarias durante la luz del día además de proporcionar un conjunto de productos estadísticos: instantánea (la cual se toma cada hora), media y la varianza. Los cuales envía a una estación remota a través de Internet.



Figura 5.1 Muestra de fotografía cámara.

Para este trabajo se descargaron las imágenes provenientes de esta EVMC, las cuales son tomadas a partir de las 6:00 am a las 18:30 aproximadamente todos los días, una foto por hora. El intervalo de tiempo de este estudio corresponde del 06 de junio del 2016 al 20 de mayo del 2021 que es el día el cual se descargaron las imágenes, juntando alrededor de 30,000 imágenes.

Estas son imágenes de baja calidad, oblicuas, con un tamaño de 960 * 1280 pixeles. A partir de un preprocesamiento que se describe posteriormente, de las 30000 imágenes resultaron 1643 fotografías. En la figura 5.1 se muestra un ejemplo de una de estas fotografías.

5.2 Imágenes satelitales

Las imágenes satelitales utilizadas en esta tesis provienen de los satélites Sentinel-2, los cuales fueron lanzados en 2015 por la Agencia Espacial Europea (ESA). Estos satélites están equipados con un instrumento multispectral (MSI) que adquiere datos en 13 bandas que abarcan el espectro visible, el infrarrojo cercano y el infrarrojo de onda corta. Este sistema proporciona imágenes ópticas de alta resolución con una resolución espacial de 10 metros en cuatro bandas, 20 metros en seis bandas, y 60 metros en tres bandas. La frecuencia de revisión de cada satélite Sentinel-2 es de 10 días, mientras que la revisión combinada de la constelación es de 5 días. La resolución espacial es de 10 metros para las bandas 2 (azul), 3 (Verde), 4 (Rojo) y 8 (NIR), que fueron las utilizadas en este trabajo. Por su resolución espectral y espacial y por ser gratuitas, se eligieron para esta tesis.

Se obtuvieron imágenes Sentinel-2 nivel 1C, que proporciona imágenes ortorectificadas en la parte superior de la atmósfera (TOA) y que están disponibles desde el 23 de junio de 2015. Estas imágenes son muy convenientes ya que, al ser productos preprocesados, no es necesario hacer correcciones atmosféricas posteriores.



Figura 5.2 Imagen de a) ROI sargazo en arena b) ROI sargazo en agua, polígono creado en la plataforma de Google Earth Engine.

Para la obtención de estas imágenes, se utilizó la plataforma Google Earth Engine (GEE), donde también se definió la región de interés (ROI) mediante el trazado de un polígono en la plataforma, cubriendo aproximadamente la misma área que las ROI de las fotografías

tomadas por la EVMC (figura 5.2). Las imágenes satelitales se seleccionaron dentro del periodo de estudio comprendido entre el 6 de junio de 2016 y el 20 de mayo de 2021, lo que resultó en un total de 288 imágenes. Estas fueron sometidas a un filtro para eliminar aquellas con más del 10% de cobertura nubosa, reduciendo el conjunto final a 251 imágenes.

6. METODOLOGÍA

La metodología de esta tesis se divide principalmente en tres partes: la metodología para la detección de sargazo en las imágenes satelitales, la metodología para la detección del sargazo en las fotografías y finalmente el análisis y correlación entre las series de datos obtenidas a partir de ambas fuentes de datos. En la figura 6.1 se observa un diagrama donde se resume todo el proceso que se llevó a cabo en este trabajo.

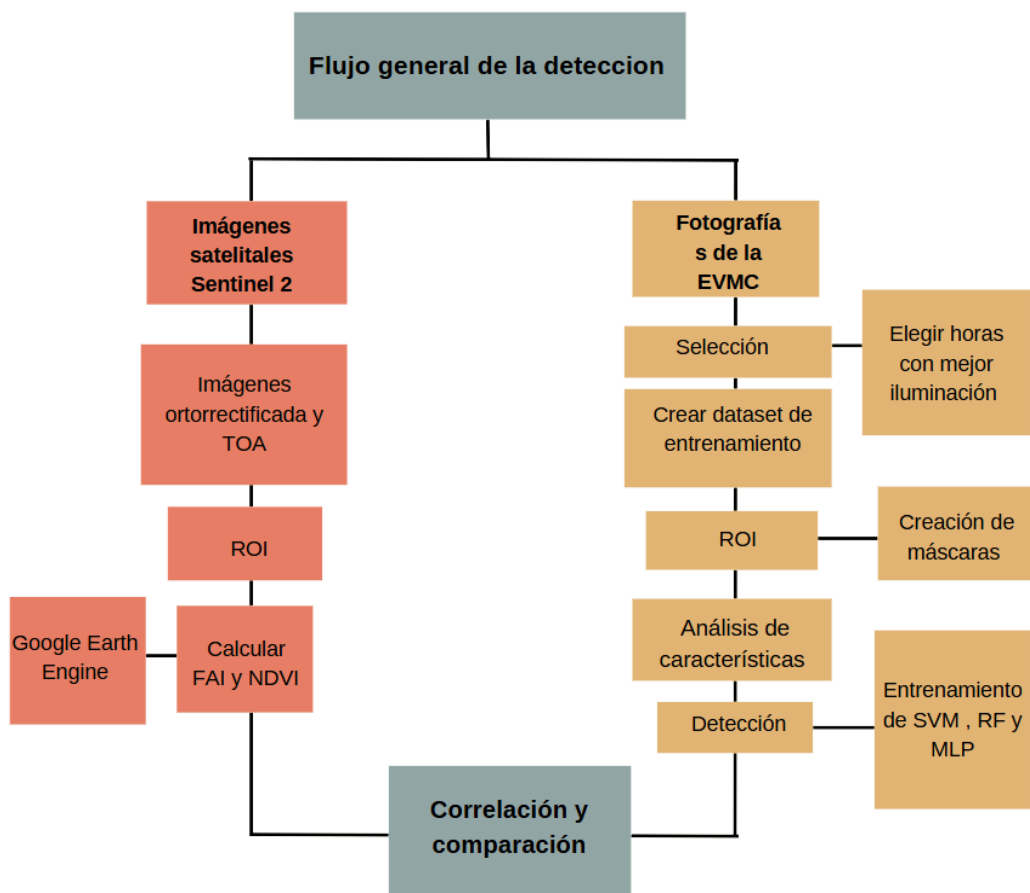


Figura 6.1. Diagrama en donde se muestra todo el proceso de detección del sargazo.

6.1 Detección de sargazo en las imágenes satelitales mediante el cálculo de índices espectrales.

Para la detección de sargazo en la playa y en el mar, se utilizaron un total de 251 imágenes satelitales Sentinel-2. A partir de estas imágenes, se calcularon los índices espectrales NDVI y FAI mediante la plataforma Google Earth Engine (GEE). Para realizar estos cálculos, fue necesario desarrollar un código en JavaScript, el cual permite seleccionar las bandas correspondientes de las imágenes satelitales y aplicar las operaciones matemáticas necesarias para obtener los índices.

El código desarrollado también incluye un filtro de cobertura de nubes, de manera que los píxeles con más del 10% de cobertura de nubes eran descartados para evitar errores al calcular los índices. Adicionalmente, se generó un código que genera las series temporales de los índices espectrales, donde cada punto en la serie representa el valor promedio de NDVI o FAI calculado dentro de la región de interés seleccionada. Puedes acceder al código en el siguiente link:

<https://code.earthengine.google.com/ea073c52c9d4a36f1ff591076619e3f3>

6.2 Detección de sargazo en las fotografías de la estación de video monitoreo costero.

Para la detección del sargazo en las fotografías de la EVMC se utilizaron métodos de Aprendizaje Automático. Se usaron cuatro métodos diferentes: Support Vector Machine con dos kernels diferentes, kernel lineal y kernel RBF; Perceptrón multicapa y Random Forest.

Para el entrenamiento de estos algoritmos se tuvo que hacer un preprocesamiento de los datos, para esto se siguieron los siguientes pasos:

- Primeramente, se hizo una selección de las fotografías óptimas para la detección de sargazo, donde se utilizó el método K-means con el método del codo y el diagrama de silueta. Esto se realiza con el objetivo de seleccionar las fotografías en las cuales el sargazo se distinguiera de los demás elementos de manera clara, debido a las diferentes condiciones de color y de luz en las fotografías.
- Realización de máscaras para delimitar la región de interés.
- Creación de un conjunto de datos de entrenamiento.
- Análisis de características de entrenamiento de los modelos.
- Entrenamiento del modelo.
- Detección/ predicción.

6.2.1 Selección de las fotografías.

Como se mencionó previamente, la EVMC captura fotografías cada hora, desde las 6:00 am hasta aproximadamente las 19:00. Como resultado, las condiciones de luz varían considerablemente a lo largo del día. Este problema puede comprenderse si se analizan las

fotografías de la figura 6.2 donde se muestran cuatro imágenes que pertenecen al mismo día, sin embargo, las condiciones de color y luz en la fotografía son muy diferentes. Por esta razón, fue necesario identificar las horas en las cuales el sargazo se puede detectar de forma clara, permitiendo así entrenar un algoritmo que lo identifique de manera efectiva. De otro modo, debido a la alta variabilidad de color y luminosidad en las fotografías, encontrar los patrones de color característicos de cada elemento, especialmente del sargazo, resultaría muy complicado.

A partir de una exploración de las fotografías, se identificaron horarios en los que las fotografías eran demasiado oscuras, lo cual no permite la observación de ningún elemento en la fotografía. También, en otros horarios, la luz solar se reflejaba en el mar, dificultando la distinción de características marinas, lo cual no es adecuado, ya que la detección del sargazo en el mar es uno de los objetivos clave de este trabajo. Sin embargo, existen ciertas condiciones del día en las que la iluminación es más favorable, lo que facilita distinguir el sargazo a simple vista de otros elementos como el agua o la vegetación. Esto se ilustra en la figura 6.3, donde en la imagen de la derecha se observa una fotografía tomada en condiciones óptimas para la detección de sargazo. En contraste, la fotografía del lado izquierdo muestra una imagen capturada en un horario en el que las condiciones de luz y color no permiten diferenciar claramente el sargazo, ya sea en el agua o en la arena.



Figura 6.2 Fotografías del mismo día (10 de junio del 2016), se puede notar la gran variación de iluminación y de características de color en cada una.

Debido a estas razones, resulta esencial identificar las horas en las cuales las condiciones de luz y color permiten una buena detección del sargazo.



Figura 6.3 Imagen de la izquierda muestra una fotografía no óptima para la detección del sargazo. La imagen de la derecha muestra condiciones de luz y color tales que permiten diferenciar el sargazo de los elementos que lo rodean.

6.2.1.1 Preprocesamiento de las fotografías de la EVMC

Para poder determinar los horarios que se caracterizaran por tener fotografías óptimas, el conjunto de fotografías se dividió en diferentes grupos, según seis características de dos espacios de color diferentes de las imágenes: el promedio de cada fotografía de los componentes rojo, verde y azul (RGB), así como también su matiz, brillo y saturación (HSV). Es decir que se representó cada foto con un vector de seis entradas (R,G,B,H,S,V)

A partir de los grupos encontrados se seleccionó el grupo con las mejores fotografías y explorando las características de este grupo óptimo se encontraron las horas que lo caracterizan. Posteriormente, de cada día, se promediaron las fotografías correspondientes a estas horas determinadas, el proceso se puede visualizar en la figura 6.4.

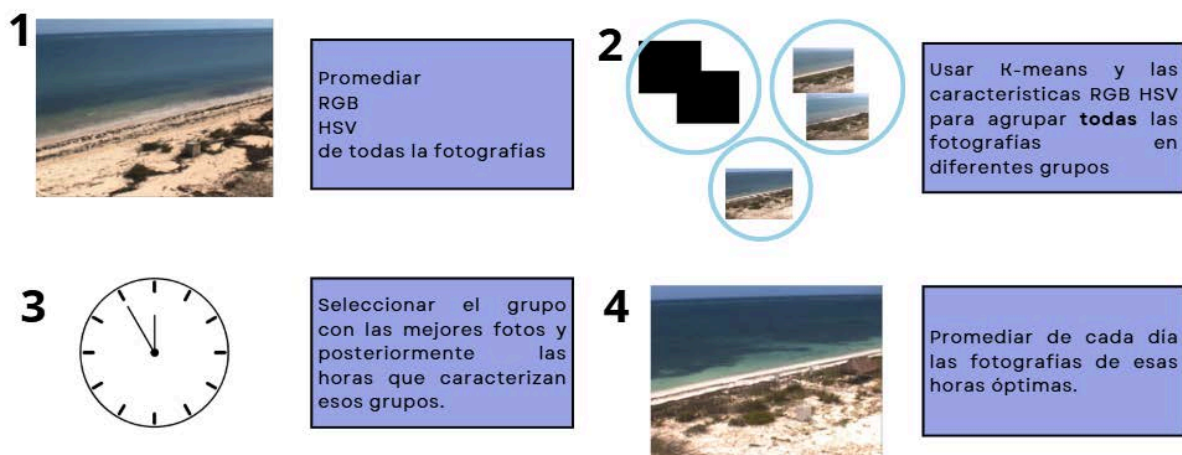


Figura 6.4 Diagrama que muestra el proceso de selección de fotografías con K-means.

Para llevar a cabo la agrupación, se implementó el algoritmo de agrupamiento K-means, en este algoritmo es necesario determinar el número de clusters K y para elegirlo se emplearon dos métodos gráficos: el método de codo y el coeficiente de silueta.

6.2.1.1.1 Método del Codo

En relación con el método del codo, se graficó la distorsión en función de los valores de K (Figura 6.6). En la gráfica 6.5 se identifican dos puntos principales de inflexión, uno en $K = 2$ y otro en $K = 4$. Para este análisis, se seleccionó $K = 4$ como el valor óptimo, ya que, a partir de este punto, la reducción en la distorsión comienza a ser menos significativa y tiende hacia cero.



Figura 6.5 Gráfico de distorsión vs Valores de K grupos, utilizando RGB HSV.

6.2.1.1.2 Gráfico de Silueta

Posteriormente para rectificar la prueba del diagrama de codo, se realizaron gráficos de silueta. En este tipo de diagrama, hay varios aspectos a considerar para elegir la mejor agrupación:

- En primer lugar, se considera el promedio del coeficiente de silueta de todo el conjunto de datos (marcado por la línea roja en el gráfico), el cual idealmente debe ser mayor a 0.5 lo que se considera como una partición considerable (Burney, 2014).
- En segundo lugar, es relevante considerar la cantidad de datos en cada clúster, representada en el diagrama por el grosor de cada uno de ellos. El equilibrio en la cantidad de datos entre los grupos puede o no ser crucial, dependiendo del problema específico (Burney, 2014). En el caso de esta tesis, aunque este factor no es primordial, sigue siendo un aspecto para tener en cuenta.

En la figura 6.6, se observa que, con $K = 2$, uno de los grupos presenta valores de silueta por debajo del promedio. Al incrementar a $K = 3$, ambos grupos muestran valores de silueta superiores al promedio, lo cual es positivo. Sin embargo, se busca una cantidad de grupos que contengan una distribución más equilibrada de los datos, para así poder diferenciar las diferentes características de cada uno de los grupos. Con $K = 4$ la cantidad de datos en cada uno de los clusters se homogeniza, además que los valores de silueta de cada uno de estos, superan el promedio. A partir de $K = 5, 6$ y 7 , aunque los valores de

silueta siguen siendo superiores al promedio, los grosores de los clústeres se vuelven muy desiguales, con algunos grupos que contienen muy pocos datos, haciéndolos apenas visibles. Estos gráficos refuerzan la elección del método del codo, confirmando que $K = 4$ es una selección adecuada para este análisis.

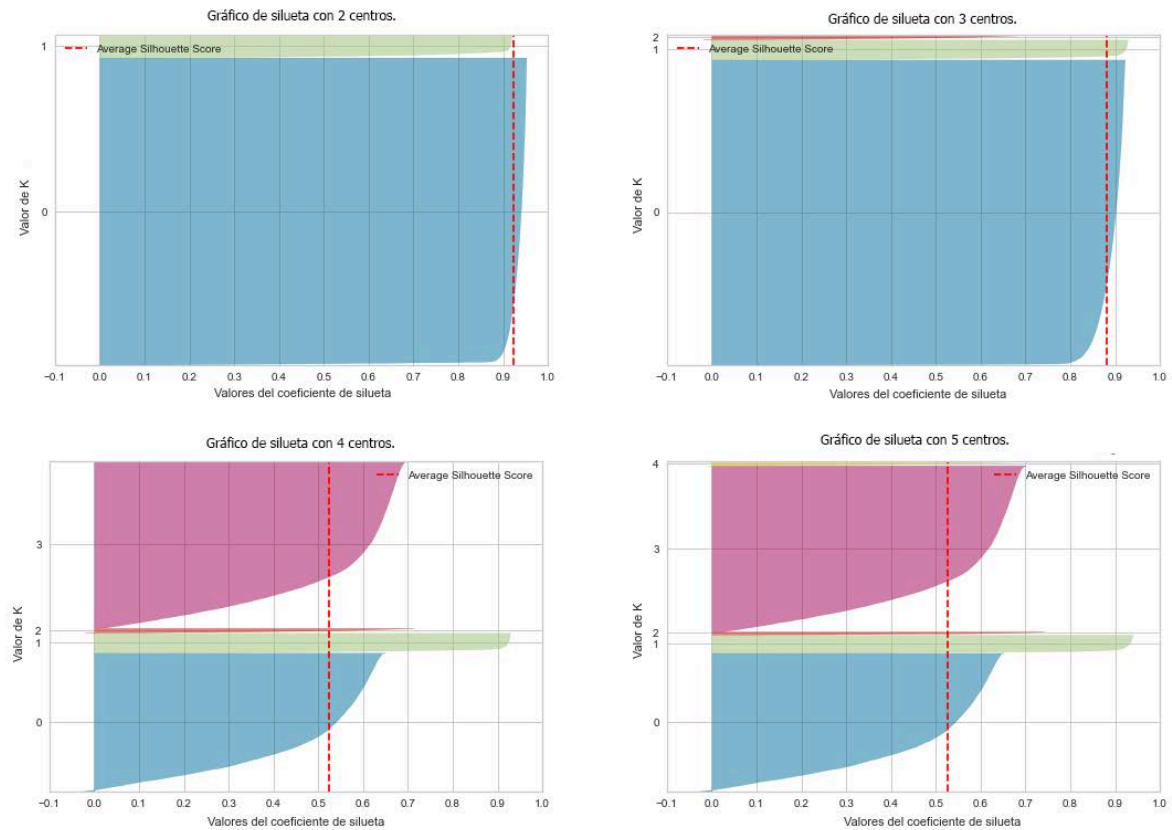


Figura 6.6 Distintos gráficos de silueta con diferentes valores de K .

Con base en estas pruebas, se confirmó que un valor de $K = 4$ es un valor que puede separar las fotografías en grupos que describen sus características principales. Es importante destacar que especificar el número correcto de grupos en el algoritmo K-means es una tarea desafiante para los investigadores y, por lo tanto, depende de cada problema, elegir el número de grupos ideal (Ali I et al., 2022).

Estos resultados también se complementaron con la realización de videos hechos con las fotografías de cada grupo, para así poder cerciorarnos de las fotografías de cada uno de los grupos y también para poder visualizar las características distintivas de cada uno de estos, permitiendo así la elección de las horas de cada día en las cuales se pueda distinguir el sargazo sobre los demás elementos de la foto.

Los videos pueden ser visualizados en el siguiente enlace:

https://drive.google.com/drive/folders/1ZcT-IYb17u_JD7VZxC4U5xBCiTg-TMfb?usp=drive_link

6.2.1.1.3 Exploración de los grupos creados a partir de K-means.

Con el objetivo de entender las características de los cuatro grupos generados a partir de la clasificación con K-means se hicieron diagramas de caja de las características RGB y HSV para cada uno de los grupos:

El grupo cero (color azul en la figura 6.8), por ejemplo, presenta valores de saturación considerablemente bajos, pero exhibe valores de brillo elevados. Además de que sus niveles de Verde, Rojo y Azul son altos en comparación con los otros grupos.

El grupo 1 se caracteriza por tener imágenes con valores RGB y brillo muy bajos, tras revisar los videos se encontró que este grupo, está conformado por fotografías oscuras por lo que las fotografías de este deberían descartarse. Estas fotografías corresponden a las horas entre 5:00 am y 6:00 am, como se ilustra en una de las fotografías que conforman la figura 6.7.

El grupo 2 se distingue por tener el valor más alto de brillo y el más bajo de saturación. Al revisar el video asociado a estas imágenes, se observa que se trata de fotografías bien iluminadas, consideradas apropiadas para la detección del sargazo, un ejemplo de esto se ilustra en la figura del grupo 2 en la figura 6.7 y corresponde a la caja verde en la figura 6.8.



Figura 6.7 Ejemplo de fotografías de cada uno de los grupos generados por el K-means.

Finalmente, el grupo 3 (representado en color morado en las gráficas) muestra una mayor dispersión en todas las características (figura 6.8). Esto es evidente en el gráfico, donde las cajas moradas de este tienen un grosor mayor en comparación con las de los otros. Al analizar los videos, se observa que estas imágenes suelen ser más oscuras, aunque conservan la suficiente iluminación para permitir la detección de elementos. Sin embargo,

en muchas de estas imágenes se refleja la luz del sol sobre el mar, lo que dificulta la distinción de elementos en la zona acuática (grupo 3 en figura 6.7).

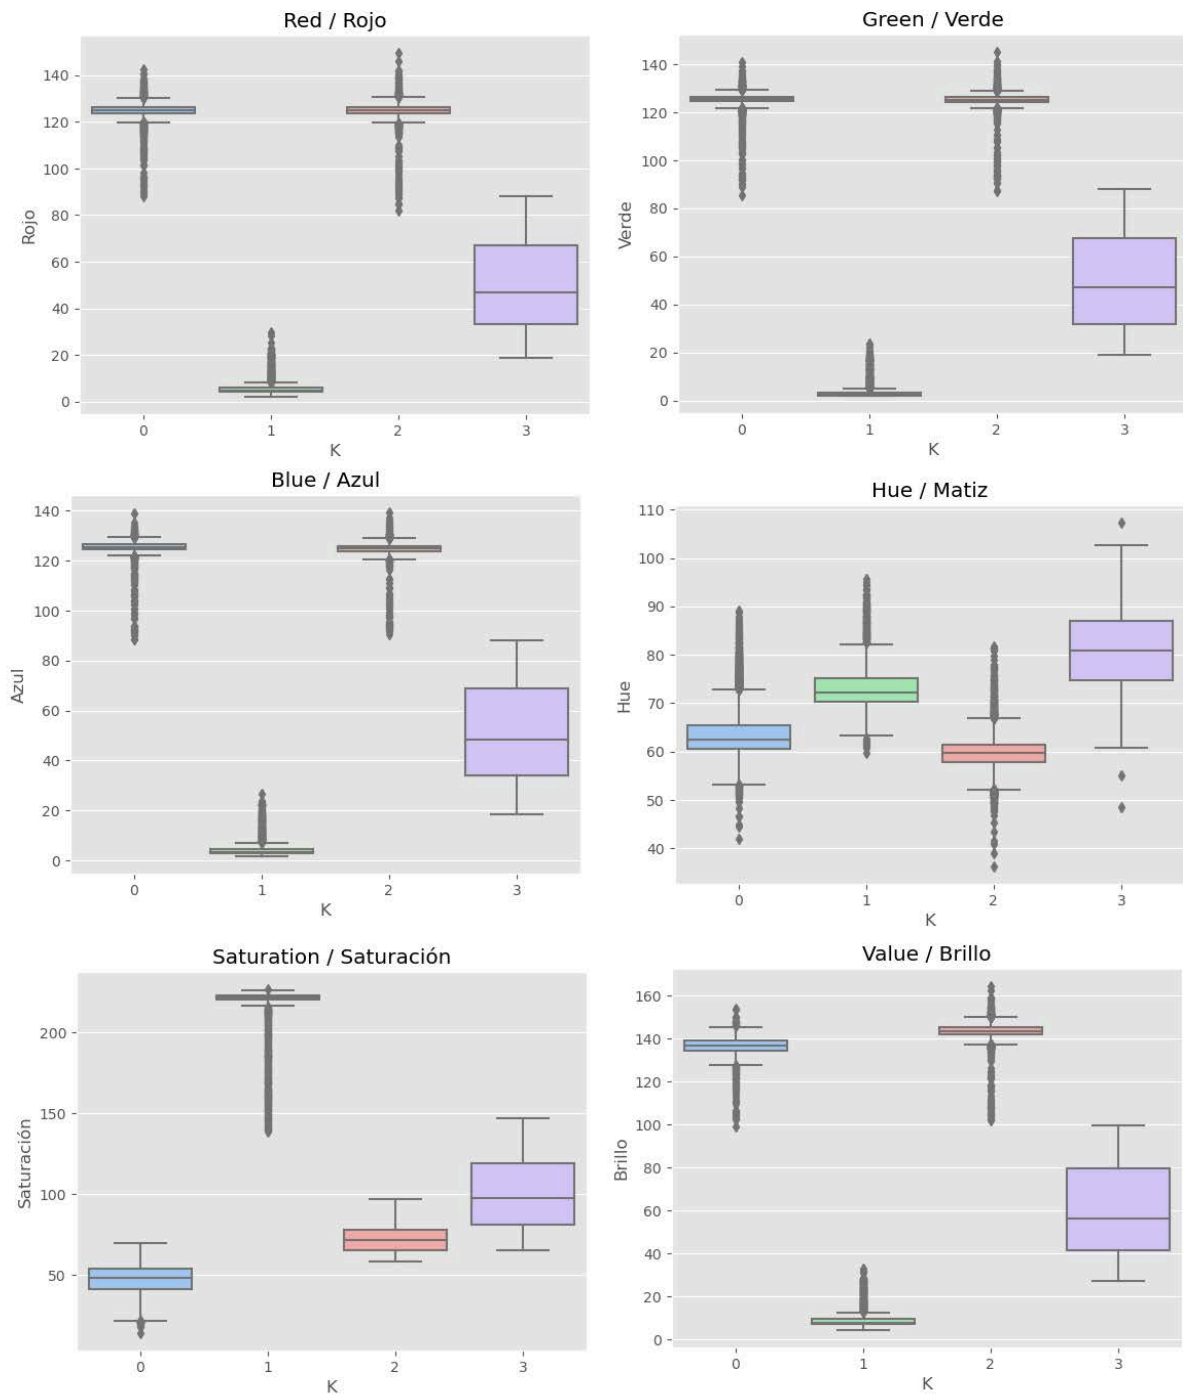


Figura 6.8 Diagramas de cajas de cada uno de los grupos creados con el K-means de cada una de las características de RGB y HSV.

A partir de estos diagramas de caja y los videos realizados, se eligió el grupo 2, como el grupo ideal para detectar el sargazo. Un grupo en el cual es más sencillo diferenciar al alga de los otros elementos principales de la fotografía.

6.2.1.1.4 Creación de una fotografía por día

Para identificar los horarios en que se tomaron las fotografías óptimas, se generó un gráfico de barras que muestra la cantidad de imágenes capturadas en cada horario (figura 6.9). En este gráfico, se observa que los cinco horarios predominantes en este grupo se encuentran entre las 12:00 pm y las 15:00 horas.

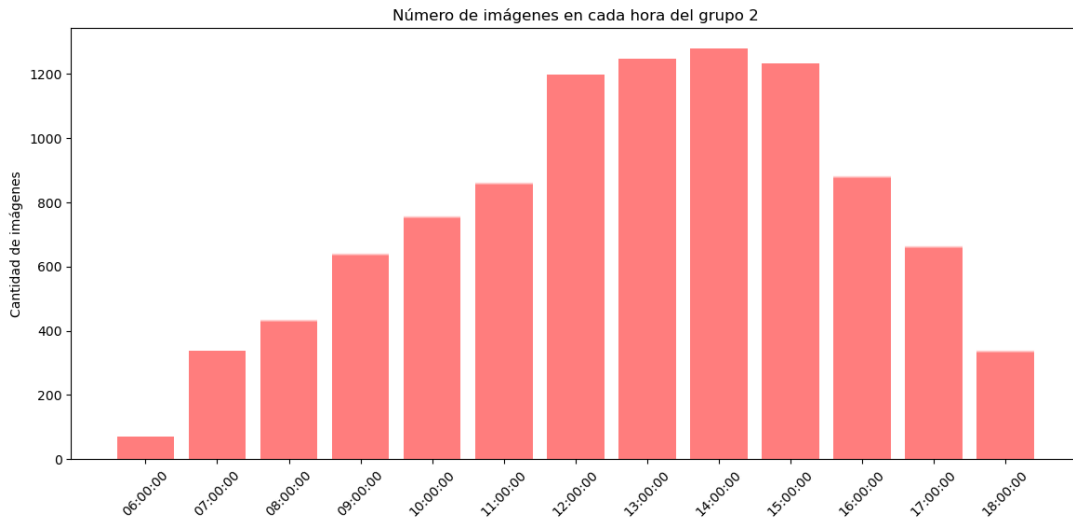


Figura 6.9 Cantidad de fotografías de cada hora en el grupo número 2.

A partir de estos resultados, se decide crear una sola fotografía por día producto del promedio de las horas ideales (12:00 a 15:00) de cada día según nuestro análisis. Es importante recalcar, que a pesar de elegir estas horas hay días en donde la iluminación fue mala en todo el día, aun así, se utiliza este método de promedios para así no descartar ningún día y tener una foto diaria. A partir de este promedio del total de 30,000 imágenes se redujeron a 1643 fotografías. En la figura 6.10 se muestran dos ejemplos de fotografías promediadas.



Figura 6.10 Fotografías promediadas, se ven algunos objetos borrosos, producto del promedio.

6.2.2 Creación del conjunto de datos entrenamiento y etiquetado.

Dado que se utilizan métodos supervisados para entrenar los algoritmos de Aprendizaje Automático, es necesario tener un conjunto de datos de entrenamiento etiquetado. Para este propósito, se utilizaron diversos conjuntos de imágenes. El periodo de las fotografías abarca desde el 6 de junio de 2016 hasta el 20 de mayo de 2021, que en total son 60 meses. Para la creación del conjunto de datos, se seleccionó una imagen representativa de cada mes de cada año, junto con doce imágenes adicionales elegidas aleatoriamente. Esta elección se hizo con el objetivo de capturar diferentes variaciones de iluminación en las imágenes y de contar con al menos una imagen que refleje las condiciones de cada mes.

Posteriormente estas imágenes fueron etiquetadas manualmente mediante la creación de máscaras binarias en Photoshop. En este proceso, se colorearon los píxeles de sargazo de blanco y los que no eran sargazo de negro, como se ilustra en la figura 6.11.




Figura 6.11 Máscara de etiquetado.

Una consideración que se tomó en cuenta para crear los algoritmos fue la presencia de dos principales medios en los que se encuentra el sargazo, sargazo seco que está sobre la arena y sargazo mojado que se encuentra flotando en el agua. Estos tienen colores y medios diferentes. Por lo tanto y para tener mejor control y precisión se decidió hacer esta separación y realizar modelos diferentes para estos dos medios (figura 6.12).



Figura 6.12 Fotografía en la cual se muestran los dos medios en los cuales se encuentra el sargazo.

A partir de las imágenes etiquetadas, se seleccionaron los píxeles a utilizar para la creación de la base de entrenamiento: Para tener una muestra equilibrada de las dos etiquetas se siguió la siguiente regla:

$$n = \min(\#Pixel \text{ sargazo}, \#Pixel \text{ No sargazo})$$

donde n = cantidad de píxeles seleccionados
 $n \text{ píxeles sargazo} = n \text{ píxeles No sargazo}$

En otras palabras, se elige la clase con menor cantidad de píxeles y esa misma cantidad de píxeles se toma de la otra etiqueta. Por ejemplo, si se tienen 2,000 píxeles de no sargazo y 4,500 de sargazo. Se van a tomar de esa imagen los 2,000 píxeles de no sargazo y la misma cantidad de sargazo.

En la figura 6.13 se observa un diagrama que muestra los conjuntos de datos para crear los algoritmos. Se etiquetó un conjunto de entrenamiento o Train (conformado por 72 imágenes) así como también un conjunto de test (conformado por 20 imágenes). Esto se realizó para dos medios diferentes: Sargazo en arena y sargazo en agua.

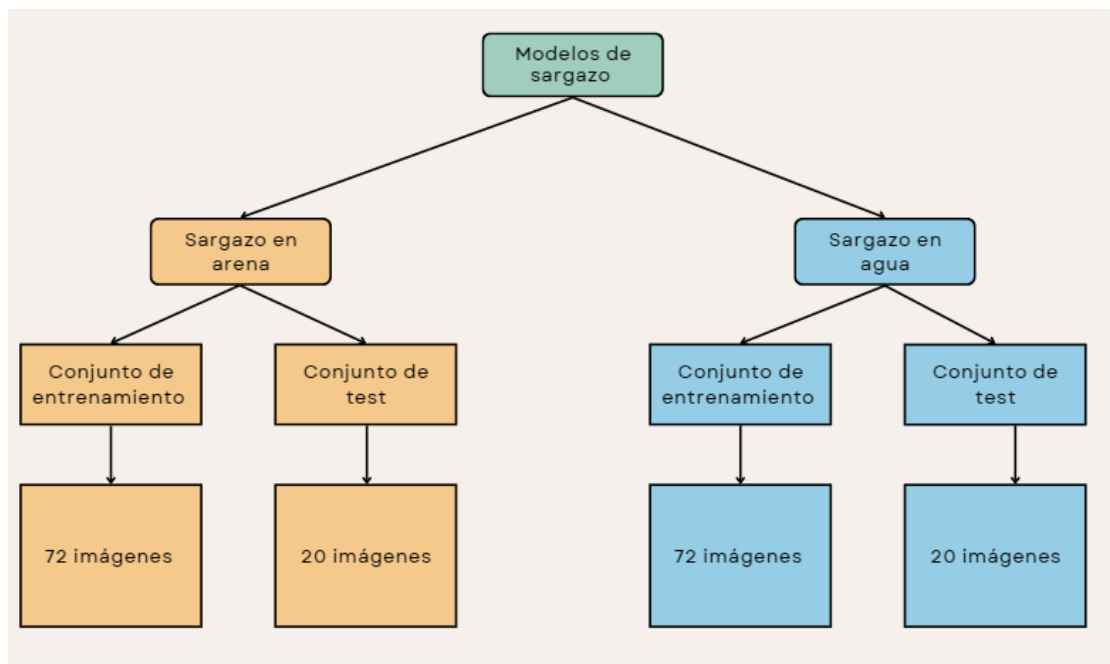


Figura 6.13 Diagrama que muestra los conjuntos de entrenamiento y de prueba para los dos medios: sargazo en arena y sargazo en agua.

6.2.3 Realización de máscaras para delimitar la región de interés.

Con el propósito de mejorar la precisión y reducir el tiempo computacional en el entrenamiento de los algoritmos, resultó esencial delimitar y seleccionar una región de interés. Esta delimitación no solo contribuye a mejorar la precisión, sino que también permite excluir elementos permanentes, como vegetación o estructuras con colores muy similares al sargazo, como la casa de palma, vegetación, entre otros. La delimitación se llevó a cabo mediante la creación de una serie de máscaras binarias en blanco y negro.

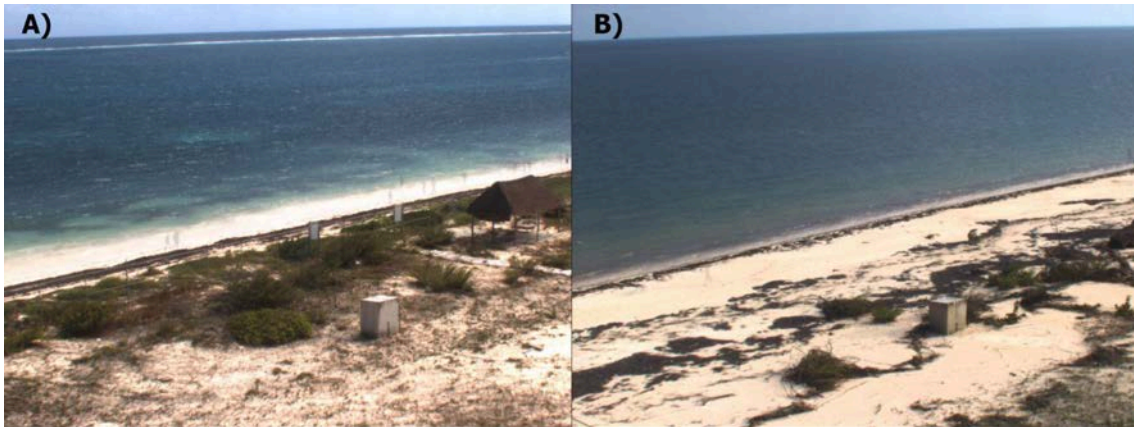


Figura 6.14 Fotografías que ejemplifican el cambio de playa antes y después del huracán Zeta A) Corresponde al 16 de febrero del 2018 (antes), B) Fotografía del 14 de noviembre del 2021 (después)

En total, se construyeron tres máscaras: una para la detección del sargazo en el agua y dos para el sargazo en la arena, correspondientes a antes y después del huracán Zeta que ocurrió del 24 al 29 de octubre del 2020, ya que este evento impactó significativamente la playa (figura 6.14), alterando muchas de sus características, como estructuras y vegetación.

La máscara final es una imagen binaria, donde la parte blanca representa el área de interés, mientras que la parte negra comprende el resto de la imagen, que no aporta información y podría introducir complejidad y confusión al algoritmo.




Figura 6.15 a) Imagen de la máscara para la detección de sargazo en agua, b) máscara para la detección de sargazo en arena, antes del huracán, c) máscara para la detección de sargazo de arena, después del huracán.

6.2.3.1 Creación de máscaras para la detección del sargazo en la Arena.

Para las máscaras en la playa se utilizó el método MOG2 Background Subtract. Este es un algoritmo de segmentación de fondo basado en una mezcla gaussiana. Se basa en dos artículos de Zivkovic (2004 y 2006). Este algoritmo funciona seleccionando algún video o generando una historia a partir de diversas imágenes, a partir de esta sucesión de imágenes el algoritmo discrimina entre píxeles de primer plano y de fondo construyendo y manteniendo un modelo del fondo, donde cada píxel tiene una función de densidad de probabilidad para cada píxel por separado. Un píxel de una nueva imagen se considera un píxel de fondo si su nuevo valor está bien descrito por su función de densidad, cualquier píxel que no se ajuste a este modelo se considera que está en primer plano (Documentación OpenCV, 2024).

6.2.3.2 Creación de máscaras para la detección del sargazo en el agua.

Para la máscara en el agua, no fue posible utilizar un método de sustracción de fondo, ya que este método no podía detectar muy bien los cambios del sargazo en el agua, por lo que la máscara se realizó a partir de la suma de las zonas de detección que se obtuvieron a mano (estas detecciones a mano corresponden a todas las imágenes etiquetadas para entrenar el algoritmo en el sargazo en agua), ya que estas representan una muestra de donde se encuentra el sargazo generalmente, y así evitamos zonas que no nos brindan información, el proceso se describe en la figura 6.16.



Figura 6.16 La máscara de agua se realizó a partir de la suma de máscaras de entrenamiento.

6.2.4 Análisis de características para los modelos

La detección de sargazo se realizó a nivel de píxel. Posteriormente de cada píxel se seleccionaron las mismas seis características de color que empleamos previamente para seleccionar los horarios óptimos de las fotografías. Estas características incluyen los valores RGB (Rojo, Verde y azul) y HSV (Matiz, Saturación, Brillo) de cada píxel (figura 6.17).



Figura 6.17 El conjunto de datos se compone de 6 valores de color diferentes para poder detectar el sargazo en las fotografías de cada pixel RGB y HSV.

En este estudio, se utilizaron árboles de decisión junto con el criterio de reducción de impureza de Gini para analizar la importancia de las características. El objetivo de este análisis es identificar cuáles son las características esenciales para la construcción de los modelos y hacer el modelo más interpretable. Saber qué características son importantes para la detección del sargazo permite explicar cómo el modelo toma sus decisiones.

Para corroborar los resultados de Gini, también se elaboraron histogramas de las seis características de los dos espacios de color (RGB y HSV), seleccionando 200,000 píxeles de cada uno de los siguientes elementos: arena, vegetación, agua, sargazo en arena y sargazo en agua. Esto con el objetivo de ver cómo se comportan las características en los elementos principales de las fotografías. Sobre todo es interesante comparar las distribuciones entre los elementos que interactúan en las fotos, como el sargazo mojado en el agua y el sargazo seco en la arena.

6.2.5 Detección del sargazo y creación de series de tiempo

Finalmente, se entrenan en este trabajo cuatro algoritmos diferentes para los dos medios del sargazo (en agua y en arena): Random Forest, Red neuronal artificial Perceptrón multicapa y Support Vector Machine con kernel lineal y con kernel de función de base radial utilizando los conjuntos de entrenamiento de la figura 6.13. A continuación se describen los hiper parámetros que se usaron para entrenar los modelos:

- Para el Random Forest se utilizó un número de árboles igual a 100, con tres características por árbol y Gini Impurity como criterio de partición.
- Para el Support Vector Machine se utilizaron dos kernel, un kernel lineal, con una función de pérdida Hinge loss y con un máximo de 1000 iteraciones y un kernel RBF. Para elegir el valor de gamma, se utilizó la opción "scale" que se calcula de la siguiente forma:

$$\gamma = \frac{1}{\#carac \times Var(S)} .$$

- Y finalmente para la construcción de la red neuronal perceptrón multicapa el cual es un total de 2 capas ocultas, con 8 neuronas cada una, la función de activación es ReLU, y el solucionador para la optimización de los pesos es ADAM, la arquitectura se puede ver en la figura 6.18.

A partir de estos modelos se hizo la detección del sargazo de las fotografías promediadas por día y se hicieron series de tiempo de cada uno de los algoritmos en donde cada punto de la serie corresponde a la densidad de pixeles detectados como sargazo de cada una de las imágenes, es decir el total de pixeles de sargazo dividido por la cantidad de pixeles de la ROI.

Es fundamental tener en cuenta que, para asignar a cada píxel una unidad en la vida real, se requiere la calibración extrínseca y la proyección de cada una de las imágenes (Simarro et al., 2017). La proyección se realiza para evitar errores en el conteo de sargazo debido a la perspectiva de la fotografía, donde las zonas más alejadas de la cámara podrían registrar menos sargazo y las más cercanas, una cantidad mayor. Debido a la falta de puntos de control, ya que solo se disponía de las imágenes, fue imposible llevar a cabo este paso. Por lo tanto, la cantidad de pixeles de sargazo detectados en esta tesis será una medida aproximada.

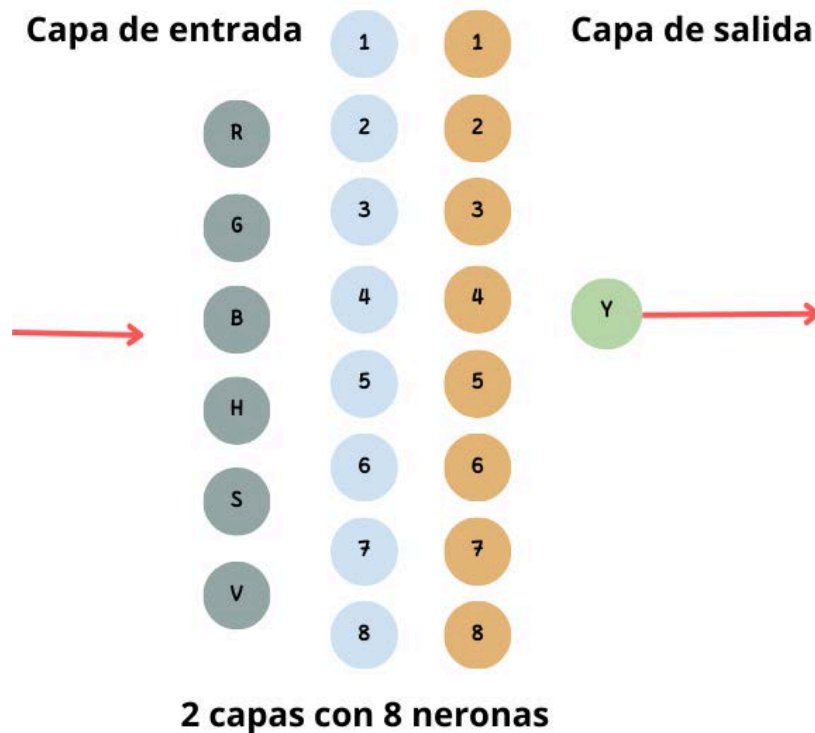


Figura 6.18 Arquitectura de la red neuronal artificial de este trabajo.

6.3 Comparación de las series de tiempo.

El análisis de series de tiempo consiste en estudiar cómo una variable evoluciona a lo largo del tiempo. En este estudio, se analizan las series de tiempo generadas a partir de fotografías de EVMC y satelitales con el objetivo de identificar patrones en la llegada y acumulación de sargazo en las costas. Este análisis permite comparar las series de tiempo, destacando tanto las diferencias como las similitudes entre ellas y así determinar si ambos métodos de detección (EVMC y satelital) registraron cantidades de sargazo consistentes o similares.

Para comparar las series de tiempo, fue necesario realizar los siguientes procedimientos:

- **Normalización estándar:** consiste en escalar los datos para que tengan media cero y varianza unitaria, equivalente a calcular la puntuación z de los datos.
- **Suavización de los datos:** Con el objetivo de eliminar el ruido presente en las series, así como también visualizar el comportamiento general de la serie sin perturbaciones. Este ruido se debe, en el caso de las imágenes satelitales, a la presencia de nubes o condiciones atmosféricas desfavorables que afectan la calidad de los datos y generan interferencias en la serie de tiempo. En el caso de las fotografías, las malas condiciones climáticas, las condiciones de la cámara como gotas en el lente o suciedad o las mismas características de las fotografías.

Para la suavización, se implementó el filtro de Savitzky–Golay, una técnica previamente utilizada con éxito para reducir el ruido en series temporales, especialmente en índices espectrales (Chen et al., 2004; Cao et al., 2018; Huang et al., 2021). En la figura 6.19 se muestra una de las series de tiempo suavizada con este filtro y cómo se observa, la serie se suaviza sin perder su forma original.




Figura 6.19 Series de tiempo de las predicciones con RNA MLP para el sargazo en agua normalizadas antes y después del filtro Savitzky-Golay.

6.3.1 Medidas de similitud entre series de tiempo.

Para obtener una medida cuantitativa de la similitud entre las series de tiempo, se calcularon las correlaciones entre las series creadas a partir de nuestro método de Aprendizaje Automático y los índices espectrales. Sin embargo, surge el primer obstáculo: las series de tiempo tienen cantidades desiguales de datos (mientras que las series de tiempo de los índices tienen 251 datos, las series correspondientes a las fotografías de la EVMC tienen 1643 datos). Esto impide el cálculo directo de un coeficiente de correlación.

Por lo tanto, se llevó a cabo una adaptación de los datos por medio de dos procesos diferentes:

- Primeramente, se crearon series de tiempo formadas por las fechas en común entre nuestro algoritmo de Aprendizaje Automático y el índice espectral a comparar. Este podría ser el método más adecuado ya que se comparan directamente los valores de la misma fecha, a estas series se les nombra como “Fechas en común”.
- La segunda forma, fue a partir de promediar las detecciones mensuales, por lo que se tiene un dato por cada mes de nuestro estudio, a estas series se les nombró como “promedios”.

Para calcular la correlación, existen dos opciones principales de coeficientes: Pearson y Spearman. La elección del coeficiente adecuado depende de la naturaleza de la relación entre los datos. Si la relación es lineal, el coeficiente de Pearson es el más apropiado. Por otro lado, si la relación es monótona (es decir, cuando una variable tiende a aumentar o disminuir en relación con la otra, pero no necesariamente de forma lineal), el coeficiente de Spearman resulta más adecuado. Para determinar el tipo de relación entre las series de tiempo, se graficaron los datos en un diagrama de dispersión y se ajustaron rectas de tendencia. Esto permitió identificar si la relación es lineal o monótona y, en consecuencia, seleccionar el coeficiente de correlación más apropiado.

Adicionalmente se hizo un análisis de correlación cruzada, el cual se usó para evaluar el grado de asociación entre las series temporales, un método que, como señala Bourke (1996), estima la correlación en función del desfase temporal. El procedimiento consistió en calcular el coeficiente de correlación entre las series, desplazar una de ellas un intervalo de tiempo, y repetir el cálculo.

6.3.1.1 Deformación temporal dinámica.

Posteriormente también se hizo un análisis de deformación temporal dinámica o mejor conocido por su nombre en inglés, Dynamic Time Warping (DTW) el cual es un algoritmo creado en los 60s utilizado para comparar y alinear dos series temporales que pueden variar en velocidad o en el tiempo (Senin, 2008). Se eligió esta métrica ya que es especialmente útil cuando las series temporales a comparar tienen tamaño diferente, pero que representan patrones similares (Senin, 2008).

A grandes rasgos el Dynamic Time Warping funciona de la siguiente manera:

Dadas dos series temporales $A = (a_1, a_2, \dots, a_n)$ de longitud $n \in \mathbb{Z}$ y $B = (b_1, b_2, \dots, b_m)$ de longitud $m \in \mathbb{Z}$.

El objetivo es encontrar un alineamiento óptimo entre A y B que minimice la distancia acumulada entre los puntos de ambas series, permitiendo que un punto en A se alinee con uno o más puntos en B, y viceversa.

El algoritmo comienza construyendo una matriz de costos C de tamaño $m \times n$ donde cada elemento $C(i, j)$, representa la distancia entre a_i y b_j . La distancia puede ser, por ejemplo, la distancia euclidiana:

$$C(i, j) = \left\| a_i - b_j \right\|^2$$

Intuitivamente $C(i, j)$ tiene un valor pequeño cuando los puntos a_i y b_j están cerca y un valor grande si son muy diferentes. La matriz de costos captura todas las distancias por pares entre las series A y B (Senin, 2008).

Una vez construida la matriz de costos, el algoritmo busca la ruta de alineación que pasa por las áreas de bajo costo, es decir, los "valles" en la matriz de costos. Esta ruta define la correspondencia entre los elementos de A y B.

Por lo que Dynamic Time Warping (DTW) encuentra un camino de alineamiento $W = (w_1, w_2, \dots, w_k)$ que minimiza la distancia acumulada.

$$D(w) = \sum_{k=1}^k c(i_k, j_k)$$

Se calcularon las distancias entre las series de tiempo utilizando la técnica de Dynamic Time Warping (DTW). Posteriormente, estas distancias se compararon para identificar qué pares de series de tiempo presentan mayor similitud.

6.3.2 Descomposición de series de tiempo

Un objetivo importante en el análisis de series temporales es la descomposición de una serie en un conjunto de componentes no observables que se pueden asociar a diferentes tipos de variaciones temporales. Con el objetivo de comprender y analizar los distintos componentes de las series de tiempo, se realizó una descomposición de series de tiempo.

Para ello, se utilizó el método aditivo (figura 6.17), en el cual se define la serie de tiempo como la siguiente suma:

$$\text{serie original} = \text{tendencia} + \text{estacionalidad} + \text{ruido}.$$

Donde se separa la serie de tiempo en su tendencia a largo plazo, su estacionalidad cíclica superpuesta a la tendencia a largo plazo y finalmente el ruido que son sus variaciones residuales, es decir cambios que tienen que ver con fenómenos individuales .

Cada una de estas componentes de las series de tiempo se compararon para ver si los dos tipos de detección muestran tendencias y estacionalidades similares o diferentes y así complementar la comparación de los dos métodos de detección.

6.3.3 Comparación con registros anteriores.

Finalmente, para confirmar los resultados de esta tesis con otra fuente de datos, se buscaron estudios que presentaran series de tiempo sobre las cantidades de sargazo detectadas en la zona de Puerto Morelos. En esta búsqueda, se encontró el artículo de Chávez et al. (2020), quienes generaron series de tiempo a partir de imágenes de Landsat 8 y una mezcla de índices espectrales: NDVI, FAI y SAVI (Índice de Vegetación Ajustado al suelo) y Random Forest. Así como también series de tiempo basadas en los reportes de sargazo removido por hoteles en el norte del Caribe mexicano, con datos proporcionados por nueve establecimientos.

Posteriormente se compararon estos resultados con los obtenidos por nosotros. La comparación se realiza únicamente de manera visual, ya que no se cuenta con la base de datos de ese trabajo, sólo con los gráficos presentados en su artículo. Con este análisis sólo se identifican las tendencias, así como picos y valles en las series de tiempo, permitiendo la comparación cualitativa de las observaciones y detecciones obtenidas en esta tesis y así comprobar nuestros resultados.

7. RESULTADOS

En esta sección se presentan los resultados obtenidos a partir del análisis de imágenes satelitales y de video monitoreo costero (EVMC), así como la efectividad de los modelos de Aprendizaje Automático empleados para la detección de sargazo. Los resultados se organizan de acuerdo con la metodología propuesta: en primer lugar, se aborda el análisis de la selección de características; en segundo lugar, se exponen los resultados de los algoritmos de Aprendizaje Automático aplicados para detectar el sargazo; y finalmente, se realiza un análisis de las series de tiempo, evaluando las correlaciones entre las detecciones realizadas a partir de las imágenes satelitales y las obtenidas mediante las fotografías del EVMC. Además, se incluye una discusión final que resume los hallazgos clave y su relevancia en el contexto del monitoreo del sargazo.

7.1 Análisis de características importantes para la detección del sargazo con algoritmos de Aprendizaje Automático

Para entender la importancia de las características HSV y RGB que se utilizarán para entrenar los modelos se hicieron dos procesos exploratorios, primero con el criterio de reducción de la impureza de Gini y posteriormente un análisis de las distribuciones de RGB y HSV de los diferentes elementos que hay en las fotografías. Dado que el sargazo en la arena y en el agua presenta colores diferentes, al igual que su entorno circundante, las características clave para su detección varían entre ambos casos. Por ello, este análisis se divide en dos partes: detección de sargazo en arena y detección de sargazo en agua.

7.1.1 Sargazo en arena

En la figura 7.1 se presentan los resultados de la importancia de las características según el criterio de reducción de impureza de Gini. De acuerdo con este gráfico, la característica más significativa fue el canal Green, seguida del Red y el Value. La saturación resultó ser la característica menos relevante según estos resultados.

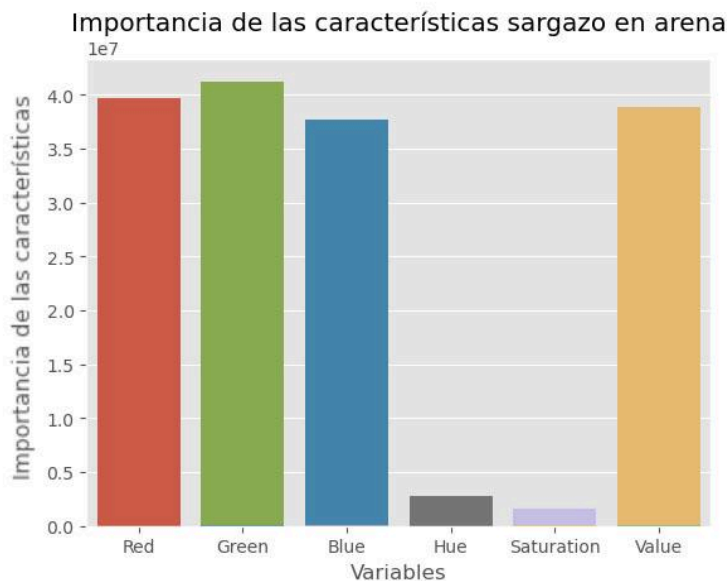


Figura 7.1. Gráfico de barras que muestra la importancia de cada una de las características para el modelo de sargazo arena, en el eje X se observa cada una de las características y en el eje Y su valor de reducción de impureza de Gini.

7.1.2 Sargazo en agua

Para el caso de la detección de sargazo de agua, se calcularon de la misma manera la importancia utilizando la reducción de impureza de Gini. Los resultados se muestran en el gráfico de barras de la figura 7.2. En este gráfico, es evidente que la característica Hue (Matiz), tiene un valor de importancia Gini significativamente más alto que las otras características, seguido por el valor de Blue, posteriormente el Red, el Value y la

Saturación. La característica Green, resultó con menor importancia a comparación de las otras características.




Figura 7.2. Gráfico de barras que muestra la importancia de cada una de las características para el modelo de sargazo de agua, en el eje X se observa cada una de las características y en el eje Y su valor de reducción de Gini impurity.

7.1.3 Análisis de las distribuciones de RGB y HSV de los diferentes elementos que hay en las fotografías.

Para explorar a fondo las seis características de los dos espacios de color (RGB y HSV), se seleccionaron 200,000 píxeles de cada uno de los siguientes elementos: arena, vegetación, agua, sargazo en arena y sargazo en agua. A partir de estos píxeles, se elaboraron histogramas que muestran cómo se distribuyen cada uno de los elementos, según las seis variables de color. Los resultados se presentan en las Figuras 7.3 y 7.4.

Con respecto al sargazo en la arena es interesante analizar las diferencias entre el sargazo seco, la arena y la vegetación, ya que estos son los elementos que interactúan en la foto por lo que se deben distinguir y diferenciar entre ellos para separar el sargazo seco. En términos de RGB, se puede observar que la arena y el sargazo seco se separan considerablemente bien en los histogramas de las variables Red y Green. En el caso de la vegetación frente al sargazo seco, la característica en la que se observa una distribución diferente es el Rojo (red), lo cual tiene sentido ya que el sargazo muestra un color más rojizo respecto a otro tipo de vegetación, esta misma lógica explica que el verde sea importante ya que la vegetación en las fotos se muestra más verde. En el espacio HSV, la arena presenta un brillo (Value) mucho mayor que los otros elementos, lo cual es comprensible, ya que la arena suele ser más reflectante y tiene tonos cercanos al blanco en comparación con los otros elementos analizados.

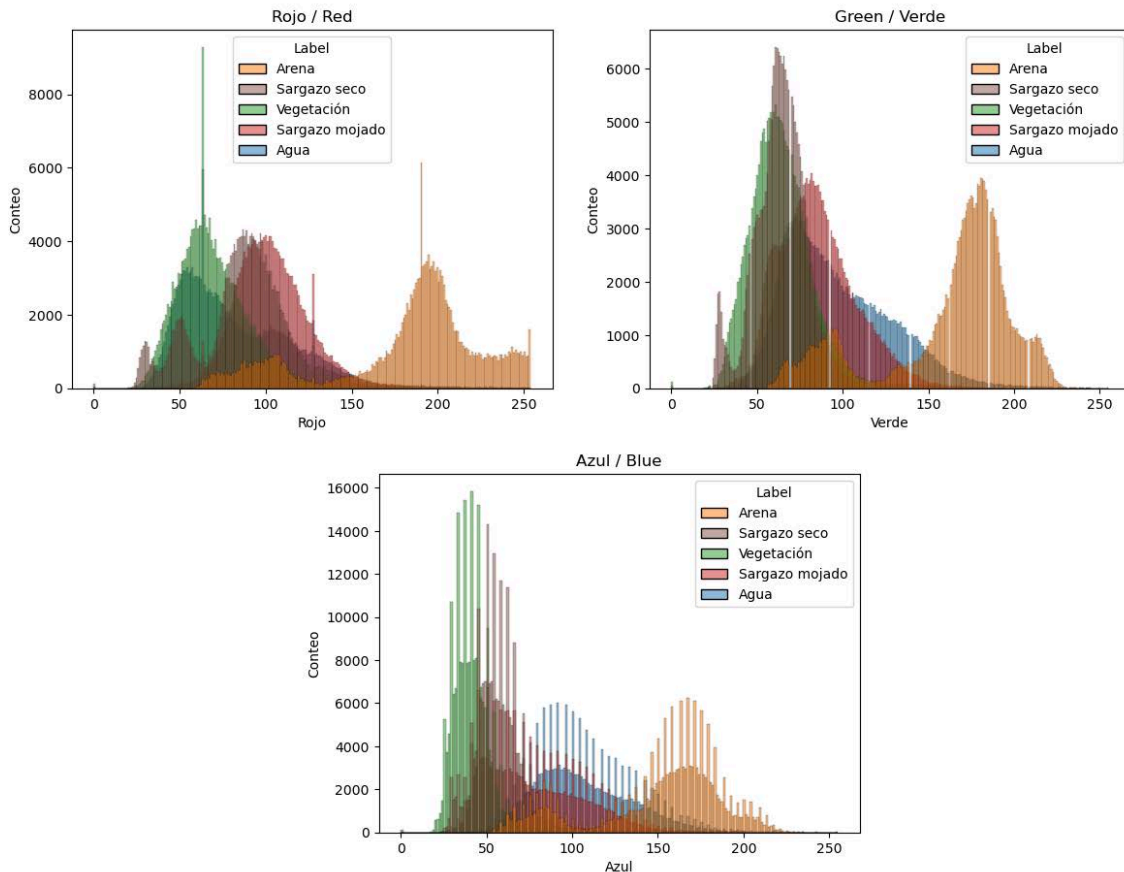


Figura 7.3 Histogramas que muestran la distribución de RGB de los principales elementos de la foto: arena, sargazo seco y mojado, vegetación y agua.

En el caso del sargazo mojado, el medio donde se encuentra es el agua, por lo que el objetivo es encontrar una característica donde las distribuciones de agua y sargazo mojado sean diferentes. En el espacio de color RGB, la diferencia en los histogramas podría estar en el azul o el rojo, pero realmente no hay una separación muy notoria y las distribuciones se interceptan considerablemente. Analizando los histogramas en el espacio HSV, la característica de matiz (Hue) es donde se observa una diferencia mucho más notoria, lo cual concuerda con los valores obtenidos a partir del ranking de reducción de impureza de Gini. Posteriormente el azul, lo cual tiene mucho sentido, al saber que se debe diferenciar el sargazo del agua que presenta colores azules en las fotos.

Estos diagramas permiten una comprensión más profunda de los resultados obtenidos en las pruebas de selección de características, al mostrar las distribuciones de los valores de RGB y HSV para los principales elementos de la fotografía. Resulta especialmente interesante observar las diferencias entre las distribuciones de elementos que interactúan, como arena y sargazo, o sargazo mojado y agua. Identificar estas distribuciones únicas en los elementos y ver su coincidencia con las características relevantes (según las pruebas de selección de características) sugiere que los valores de cada uno de los elementos pueden diferenciarse y separarse de otros elementos.

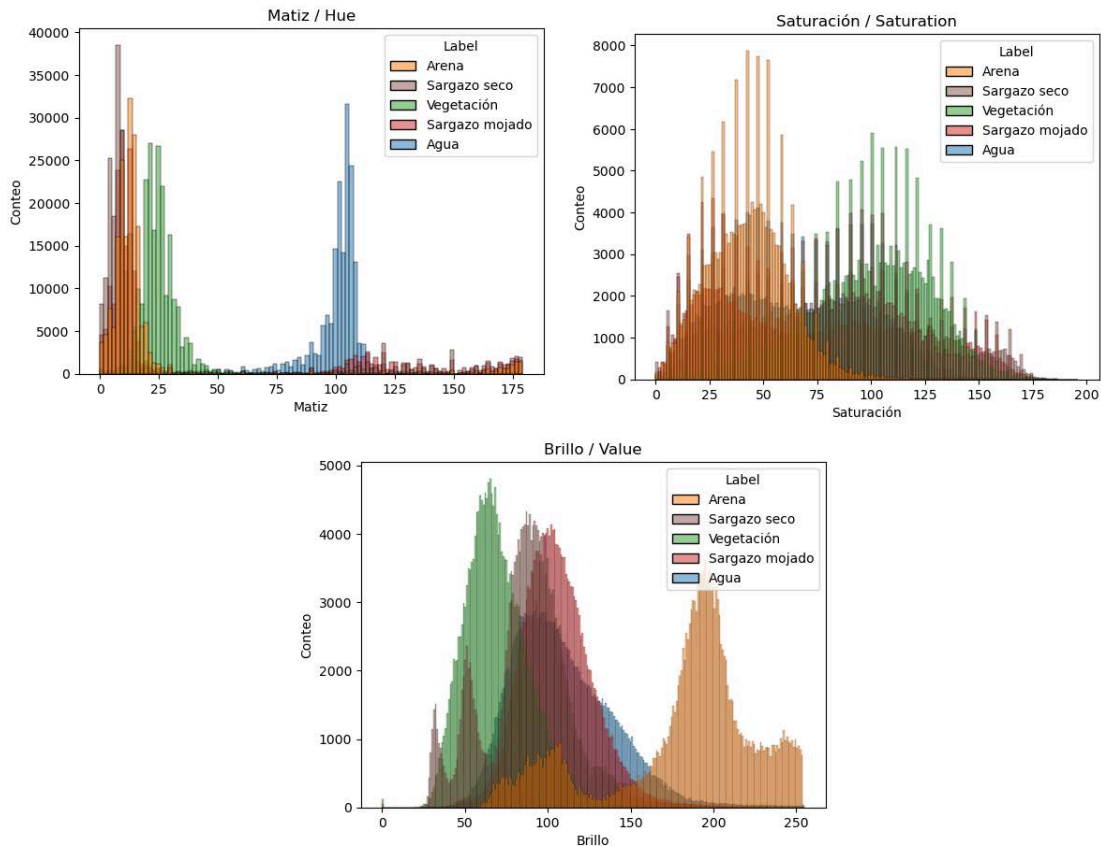


Figura 7.4 Histogramas que muestran la distribución de HSV de los principales elementos de la foto: arena, sargazo seco y mojado, vegetación y agua.

Se podrían haber realizado más pruebas para descartar ciertas características y seleccionar solo las más relevantes en la creación de los modelos. Sin embargo, dado que solo se disponía de seis características, se optó por entrenar los modelos utilizando cada una de estas.

7.2 Detección del sargazo en las imágenes del video monitoreo costero utilizando algoritmos de Aprendizaje Automático

Para la detección del sargazo en las fotografías, se entrenaron cuatro algoritmos diferentes: Random Forest, Red neuronal Perceptrón Multicapa y Support Vector Machine con dos diferentes kernels; kernel lineal y un kernel de función de base radial. Esto se hizo para los dos medios sargazo en arena y sargazo en agua.

7.2.1 Modelos sargazo en arena

En esta sección se entrenaron los modelos de aprendizaje automático para la detección de píxeles de arena, utilizando los algoritmos mencionados en la sección 6.2.5, que son Random Forest RF, SVM lineal y con kernel RBF y una RNA. Posteriormente, se evaluaron

estos modelos con el conjunto de test de sargazo en arena (test arena) y adicionalmente se calculó el promedio de las métricas F1 y la exactitud mediante validación cruzada con diez iteraciones, esta validación se hizo con el objetivo de evaluar el rendimiento de una manera más confiable y evitar que la calificación sólo dependiera de un conjunto único de test.

En la tabla 7.1 se presentan los resultados, donde se observa que tanto los valores de F1 como de exactitud, evaluados en el conjunto de test y en la validación cruzada, superan 0.85 en casi todos los algoritmos, salvo el SVM lineal, que registró un valor de F1 de 0.7905 en el conjunto de test y de 0.7575 en la validación cruzada. Cabe destacar que el modelo de red neuronal artificial MLP fue el que mostró la mejor exactitud en esta tarea y que se señala en negritas en la tabla 7.1.

Durante el proceso de entrenamiento y evaluación de los algoritmos, los tiempos de entrenamiento variaron considerablemente. En la tabla 7.1 se detallan estos tiempos, donde se destaca que el SVM lineal fue el algoritmo más rápido tanto en entrenamiento como en predicción, aunque su rendimiento fue el más bajo en comparación con los otros modelos. En contraste, la RNA MLP fue el algoritmo más lento en la fase de entrenamiento, requiriendo 315.24 segundos para completar este proceso, pero mostró una rápida predicción en el conjunto de evaluación, con solo 3.9 segundos, a diferencia del SVM con kernel RBF, que necesitó 870 segundos. La figura 7.6 complementa estos hallazgos ilustrando cómo los diferentes modelos detectan el sargazo en la misma imagen, destacando los píxeles de sargazo en rojo.

Tabla 7.1 Valores de rendimiento F1 y exactitud evaluados con los datos de prueba de arena y agua, así como el promedio de las métricas a partir de la validación cruzada. También se muestran los tiempos de entrenamiento y predicción de cada modelo.

Modelos entrenados para detectar el sargazo en arena						
		Rendimiento			Tiempo (s)	
		Test arena	Validación cruzada (promedio)	Test agua	Entrenamiento	Predicción
Random Forest	F1 Exactitud	0.8570 0.8570	0.8532 0.8431	0.5577 0.5021	218.029	5.8667
RNA MLP	F1 Exactitud	0.8898 0.8831	0.8638 0.8614	0.5878 0.5192	315.240	3.9469
SVM RBF	F1 Exactitud	0.8695 0.8658	0.8586 0.8531	0.6125 0.5390	244.302	870.755
SVM Lineal	F1 Exactitud	0.7905 0.8144	0.7575 0.7571	0.4778 0.5751	201.084	3.2037

De manera complementaria, se hizo una prueba para evaluar la necesidad de tener modelos de detección de sargazo en dos medios: en sargazo en arena y en agua, en este caso se utilizaron los modelos de arena para predecir píxeles de sargazo en agua. En la tabla 7.1 se observa que tanto el valor F1 como la exactitud son mucho más bajas a

comparación de la detección en arena, como era de esperarse. El modelo SVM con kernel RBF fue el que tuvo la mayor exactitud con un valor de 0.6125. Estos valores bajos de rendimiento podrían confirmar la necesidad de tener dos modelos, un modelo que detecte el sargazo en agua y otro en arena.



Figura 7.5 Gráfico en donde se pueden visualizar las series de tiempo correspondientes a la cantidad de sargazo detectado con cada uno de los modelos, estas series de tiempo ya se encuentran suavizadas y normalizadas

En el gráfico 7.5 se muestran las series de tiempo normalizadas de las cantidades de píxeles detectados como sargazo en los 4 modelos de aprendizaje. Es evidente que las predicciones son notablemente similares entre sí. La única serie de tiempo que se ve ligeramente diferente corresponde a la generada con el modelo de SVM con kernel lineal.

Para una evaluación cuantitativa de la similaridad entre las predicciones de nuestros modelos, se calcularon las distancias entre las series utilizando Dynamic Time Warping (tabla 7.2). Los resultados revelan que las series, que tienen una menor distancia entre ellas son las de RF con MLP, por lo que se puede asumir que son más parecidas, las series con una mayor diferencia corresponden al SVM lineal, con los demás algoritmos. En la figura 7.8 se observa cómo los diferentes algoritmos detectan el sargazo, y como se observa que las detecciones (píxeles pintados en rojo) son muy parecidas en las cuatro imágenes.

Tabla 7.2 Distancias calculadas entre las series de tiempo generadas a partir de los cuatro modelos entrenados en el sargazo en arena.

	RNA MLP	RF	SVM RBF	SVM Lineal
RNA MLP	0.0	0.512	0.833	1.426
RF	0.512	0.0	0.935	1.340
SVM RBF	0.833	0.935	0.0	1.712
SVM Lineal	1.426	1.340	1.712	0.0

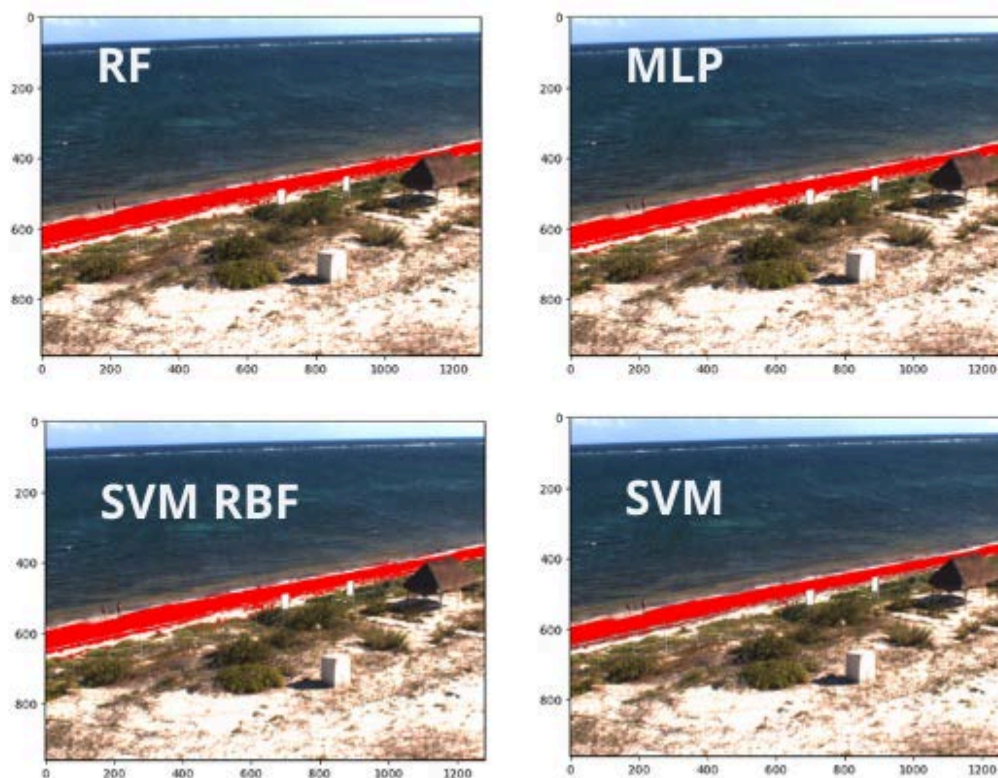


Figura 7.6 Predicciones de los distintos algoritmos de Aprendizaje Automático, los pixeles detectados como sargazo se encuentran coloreados en rojo.

7.2.2 Modelos sargazo en agua

En lo que respecta a los modelos utilizados para entrenar la detección de sargazo en agua, en la tabla 7.3 se detallan los valores F1 y de exactitud para la detección de sargazo en agua y se resalta en negrita el modelo con el valor más alto, que fue el Random Forest, seguido por el SVM con kernel RBF y luego la red neuronal, pero las variaciones son mínimas. Todos con valores de rendimiento superiores a 0.70, con la excepción del SVM con kernel lineal que arrojó valores de exactitud alrededor de 0.65.

Tabla 7.3 Valores de rendimiento F1 y exactitud de los algoritmos entrenados para la detección del sargazo en agua, evaluados con los datos de test de agua y arena, así como el promedio de las métricas a partir de la validación cruzada. También se muestran los tiempos de entrenamiento y predicción de cada modelo.

Modelos entrenados para detectar sargazo en agua						
		Rendimiento			Tiempo (s)	
		Test agua	Cross validation	Test arena	Entrenamiento	Predicción
Random	F1	0.7299	0.7599	0.8221	291.481	22.37

Forest	Exactitud	0.7695	0.8133	0.8339		
RNA	F1	0.7283	0.7490	0.8021		
MLP	Exactitud	0.7688	0.8059	0.8029	330.10	3.94
SVM	F1	0.7295	0.7598	0.8126		
RBF	Exactitud	0.7691	0.8087	0.8215	637.54	574.63
SVM	F1	0.6712	0.6123	0.6477		
Lineal	Exactitud	0.6913	0.7053	0.6593	255.29	1.82

Al comparar estos resultados con los rendimientos de los modelos de sargazo en arena, se puede notar que son ligeramente más bajos. Esto se debe principalmente a que la detección de sargazo en agua era una tarea más difícil, incluso en algunas fotografías, con nuestro ojo humano era muy complicado identificar si se trataba de sargazo o no por ejemplo en la figura 7.8 se muestran dos fotografías en las cuales no es tan fácil identificar exactamente el sargazo en el agua.

Para comparar las series de tiempo, así como en el sargazo en arena se calcularon las distancias entre las series con DTW, la distancia más corta resultó entre las series RF y MLP, como en sargazo en arena. Las distancias mayores corresponden a las series SVM con los otros algoritmos, el cual notablemente se ve diferente en la figura 7.7, donde se muestran las series de tiempo normalizadas, de las cantidades de pixeles detectadas por fotografía y se puede apreciar también la diferencia de las detecciones entre los modelos, donde las predicciones del SVM lineal son significativamente distintas a las de los demás modelos.



Figura 7.7 Series de tiempo de los cuatro modelos de Aprendizaje Automático entrenados, donde cada uno de los puntos corresponde a la cantidad de pixeles de sargazo detectados.

Adicionalmente en la figura 7.9 se muestra un ejemplo de las detecciones de sargazo en agua, de la misma fotografía correspondientes. En este caso, se observa claramente que el modelo de SVM lineal, detecta diferentemente al sargazo en comparación con los otros modelos, lo que respalda los resultados de la correlación. Esto junto a los valores de rendimiento calculados, sugiere que un hiperplano en el espacio original no es capaz de dividir las clases de manera tan efectiva como un hiperplano en otro espacio. Es decir,

utilizando el kernel RBF, que tiene una mayor flexibilidad, se logra una mejor separación de las clases.

En cuanto a los tiempos de entrenamiento, se notó que el algoritmo más rápido fue el SVM lineal. Por otro lado, mientras que la RNA MLP tuvo tiempo prolongado de entrenamiento, su tiempo de predicción fue de sólo 3.94 segundos. En el caso del SVM, se encontró que el kernel lineal presentaba tiempos de entrenamiento y predicción relativamente cortos, pero su rendimiento fue considerablemente inferior en comparación con otros algoritmos, igual que con los algoritmos entrenados para el sargazo en arena.



Figura 7.8 Fotografías en las cuales es difícil detectar el sargazo en el agua.

En contraposición, el kernel RBF, aunque demostró ser significativamente más lento en ambos procesos, tuvo un buen rendimiento, como se evidencia en la tabla 7.3.




Figura 7.9 Detección de sargazo en agua, con los cuatro modelos entrenados .

De igual manera se utilizaron estos modelos para detectar el sargazo en arena, donde se observa que Random Forest pudo predecir el sargazo en arena con valores F1 y exactitud mayores a 0.80, sin embargo, al comparar del modelo entrenado sólo para detectar en arena, la exactitud baja hasta un 10% una reducción considerable, que nos vuelve a sugerir que la creación de un modelo para los dos medios puede ser una buena decisión.

Tabla 7.4 Distancias calculadas con DTW entre las series de tiempo generadas a partir de todos los cuatro modelos entrenados para la detección del sargazo en agua.

	RNA MLP	RF	SVM RBF	SVM Lineal
RNA MLP	0.0	1.206	5.469	12.662
RF	1.206	0.0	5.438	12.608
SVM RBF	5.469	5.438	0.0	11.924
SVM Lineal	12.662	12.608	11.924	0.0

7.3 Análisis de series de tiempo.

En esta sección del trabajo, se realizó un análisis comparativo entre las series de tiempo de los índices espectrales y las series generadas mediante los modelos de Aprendizaje Automático. Para este análisis, se han seleccionado las series de tiempo de las detecciones generadas con la RNA MLP para la detección de sargazo en arena y el algoritmo Random Forest RF para la detección de sargazo en agua. Estos modelos fueron elegidos debido a que demostraron los valores más altos de rendimiento en cada uno de los medios.

En la figura 7.10, se presenta un gráfico que ilustra la cantidad de imágenes Sentinel-2 disponibles por mes. Se observa que la cantidad varía, alcanzando un máximo de 7 imágenes y un mínimo de solo una imagen por mes. Además, se destaca que antes del año 2018, la cantidad de imágenes es inferior en comparación a los años posteriores. Esta variabilidad en la disponibilidad de imágenes es crucial, ya que la limitada cantidad de datos en los primeros meses de la serie de tiempo influirá en nuestro análisis de correlación.

Para comparar las series de tiempo es importante realizar pruebas estadísticas que proporcionen una evaluación cuantitativa de las similitudes entre ellas. En este caso, se calculó la correlación de las series generadas con el modelo de detección de píxeles con cada uno de los índices espectrales, también se descompusieron las series para analizar su tendencia y estacionalidad y comparar estos elementos de las series arrojadas por los dos métodos de detección.




Figura 7.10 Gráfico de puntos en donde el eje y corresponde a la cantidad de imágenes por mes y el eje x a cada uno de los meses de nuestro periodo de estudio.

Los coeficientes de correlación son herramientas estadísticas que permiten cuantificar la relación entre dos conjuntos de datos. Para seleccionar el coeficiente de correlación más adecuado en este análisis, fue necesario evaluar el tipo de relación entre las variables, para eso se hicieron diagramas de dispersión entre los pares de series de tiempo a compara y se ajustaron rectas a cada uno de los pares. En la figura 7.11 se muestran los diagramas de dispersión y las rectas ajustadas para cada caso.

A partir de estos diagramas se observa que las series de tiempo de sargazo en arena presentan una mayor dispersión en comparación con las de sargazo en agua, donde fue posible identificar una tendencia lineal más clara. En el caso del sargazo en arena, la relación parecía ser monótona, pero no necesariamente lineal. Al analizar los coeficientes de correlación de Pearson (R), derivados del ajuste de recta, se encontró que, para MLP vs NDVI en arena, el valor de R fue de 0.600, lo que indica una correlación positiva moderada, con un valor P de 5.889e-23, confirmando su significancia estadística.

Tabla 7.5 Coeficientes de los ajustes de recta R y su valor P de cada par de series de tiempo.

Ajuste de Recta		R (Pearson)	Valor P
Arena	MLP vs NDVI	0.600	5.88e-23
	MLP vs FAI	0.401	2.37e-09
Agua	RF Vs NDVI	0.735	2.55e-40
	RF vs FAI	0.689	4.98e-34

En el caso del sargazo en agua, se observó una mayor fuerza en la relación lineal, como se evidencia en los valores de R para RF vs NDVI (0.735) y RF vs FAI (0.690), ambos con valores P extremadamente bajos (2.557e-40 y 4.982e-34, respectivamente), lo que indica correlaciones positivas fuertes y altamente significativas. Sin embargo, en el caso de MLP vs FAI en arena, el valor de R fue menor a 0.5 (0.401), lo que podría sugerir una correlación

lineal débil. En este caso, sería recomendable complementar el análisis utilizando el coeficiente de Spearman. Para los demás casos, donde los valores de R superan 0.5 y los valores de P son muy pequeños, el coeficiente de Pearson es suficiente para interpretar la correlación (tabla 7.5). En esta tesis se van a calcular ambos coeficientes de correlación pero tomando en cuenta este breve análisis.

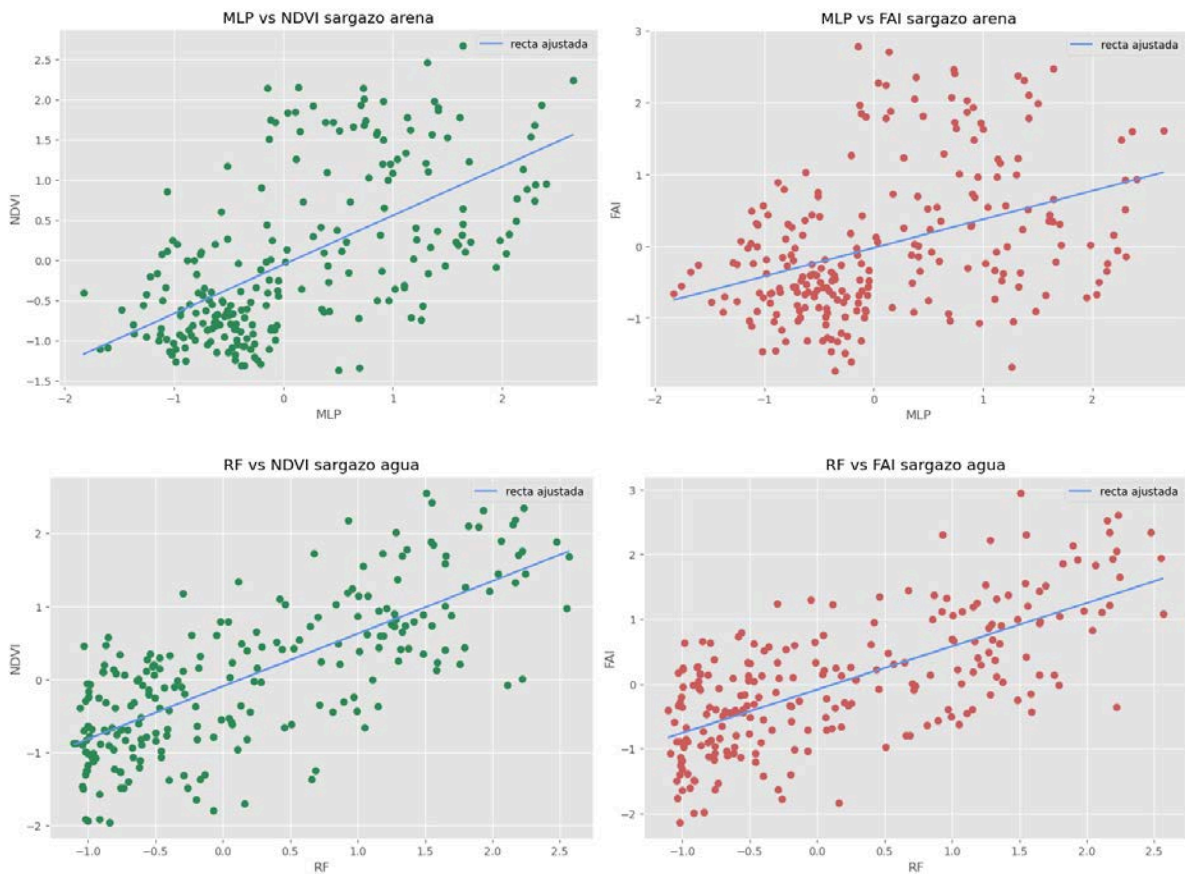


Figura 7.11 Diagramas de dispersión de las series de tiempo de las fotografías vs. los índices espectrales así como su recta ajustada en azul.

7.3.2 Series de tiempo de la detección del sargazo en arena.

En esta sección se analizan las series de tiempo generadas a partir de los valores de detección utilizando NDVI, FAI y la RNA Perceptron Multicapa (esta serie de tiempo corresponde a la densidad de pixeles detectados como sargazo en la ROI) las cuales fueron suavizadas con el método Savitzky–Golay. Primeramente, se detalla el cálculo de correlación entre las tres series de tiempo, posteriormente un análisis visual para comparar las series y finalmente se muestra la descomposición de las series de tiempo.

7.3.2.1 Cálculo de la correlación

Para calcular la correlación se utilizaron las series de tiempo adaptadas para que tengan la misma cantidad de datos, es decir que tenga la misma cantidad de datos las series de los índices espectrales con la serie generada a partir de nuestros modelos (serie llamada “fechas en común”), estas adaptaciones son mencionadas en la sección 8.3.1. En la figura 7.12 están graficadas las series de tiempo realizadas a partir de los promedios mensuales, mientras que en la figura 7.13 se muestran las series de tiempo en las cuales las fechas son coincidentes. De azul se muestra la serie generada a partir de la detección de pixeles en las fotografías, en verde el NDVI y en rojo el FAI de las imágenes Sentinel-2.

Visualmente, se observa que las tres series de tiempo son similares y muestran una estacionalidad anual, con un incremento en la presencia de sargazo durante los meses de mayo a agosto, que corresponden al período de primavera y verano en México. Los años con mayor concentración de sargazo son 2018, 2019, lo cual concuerda con diversos registros, incluyendo el estudio de Rodríguez Martínez et al. (2022) y Chávez et al., 2020.




Figura 7.12 Series de tiempo adaptadas para tener el mismo número de datos. En este caso son las series generadas a partir del promedio por mes.




Figura 7.13 Series de tiempo adaptadas para tener el mismo número de datos en este caso son las series de tiempo en las cuales corresponden las fechas de la imagen satelital y la fotografía.

En la tabla 7.6 se muestran los resultados de la correlación tanto Spearman como Pearson, donde el valor de coeficiente de Spearman más alto es de 0.635 y corresponde a la correlación entre la serie de NDVI y el modelo RNA MLP generado a partir de los promedios mensuales. Posteriormente, se observa una correlación Spearman de 0.614 entre NDVI y RNA MLP en las series de tiempo creadas a partir de fechas en común, las cuales consideramos de mayor relevancia, ya que esta correlación compara directamente los datos correspondientes en cada serie en función de su fecha, en cambio las series de promedio mensual podrían considerarse como series de tiempo suavizadas con una ventana mensual. Estos resultados confirman la presencia de una correlación positiva entre la serie de NDVI y el modelo RNA MLP según el coeficiente de Spearman.

Por otro lado los valores P de todas las correlaciones son menores al valor de significancia 0.05, por lo que los resultados son significativamente estadísticos.

Tabla 7.6 Coeficientes de correlación para las series de tiempo de sargazo en arena.

Coeficientes de correlación		RNA MLP con:			
		Coeficiente Spearman		Coeficiente Pearson	
		NDVI	FAI	NDVI	FAI
Fechas en común	Stat	0.614	0.392	0.600	0.400
	Valor P	1.66e-29	5.00e-08	2.37e-09	4.029e-10
Promedio por mes	Stat	0.635	0.405	0.615	0.419
	Valor P	1.227e-11	0.0022	3.857e-07	0.001

Sin embargo, esta relación no se manifiesta de la misma manera con las series del índice FAI donde la correlación más alta obtenida es de 0.405. Esto era previsible, dado que el FAI no está diseñado para detectar sargazo en arena, sino en agua. Por lo tanto, no es sorprendente que la capacidad del FAI para detectar el sargazo seco sobre la arena sea limitada y por ende la correlación es menor, aun así, al ver la serie de tiempo de FAI, observamos que refleja el comportamiento general de las otras dos series de tiempo (NDVI y RNA MLP).

En cuanto a los valores de correlación de Pearson, estos son ligeramente más bajos a los de Spearman, lo que puede sugerir que la relación entre las series de tiempo puede ser más monótona que lineal, o que hay factores como valores atípicos o no normalidad que están influyendo en los resultados. Sin embargo son muy parecidos y coincide con la interpretación con la de el coeficiente de Spearman.

- Correlación cruzada

Como se menciona en la sección metodológica, se calculó también la correlación cruzada esto con el objetivo de encontrar la relación entre dos series de tiempo y, en caso de que exista, cuál es el desplazamiento temporal (lag) óptimo entre ellas.

En las series de tiempo de fechas en común la correlación de MLP con NDVI coincide con el lag 0 y su valor es de 0.6 con FAI también es con el lag 0.4. En cuanto a las series de tiempo de promedio por mes el coeficiente de correlación más alto se da en el lag 0 con NDVI es 0.6 y FAI 0.42. Estos valores corresponden a los valores de Pearson calculados anteriormente. Lo que significa que la correlación más fuerte entre las series se da cuando no hay un desplazamiento temporal entre ellas.

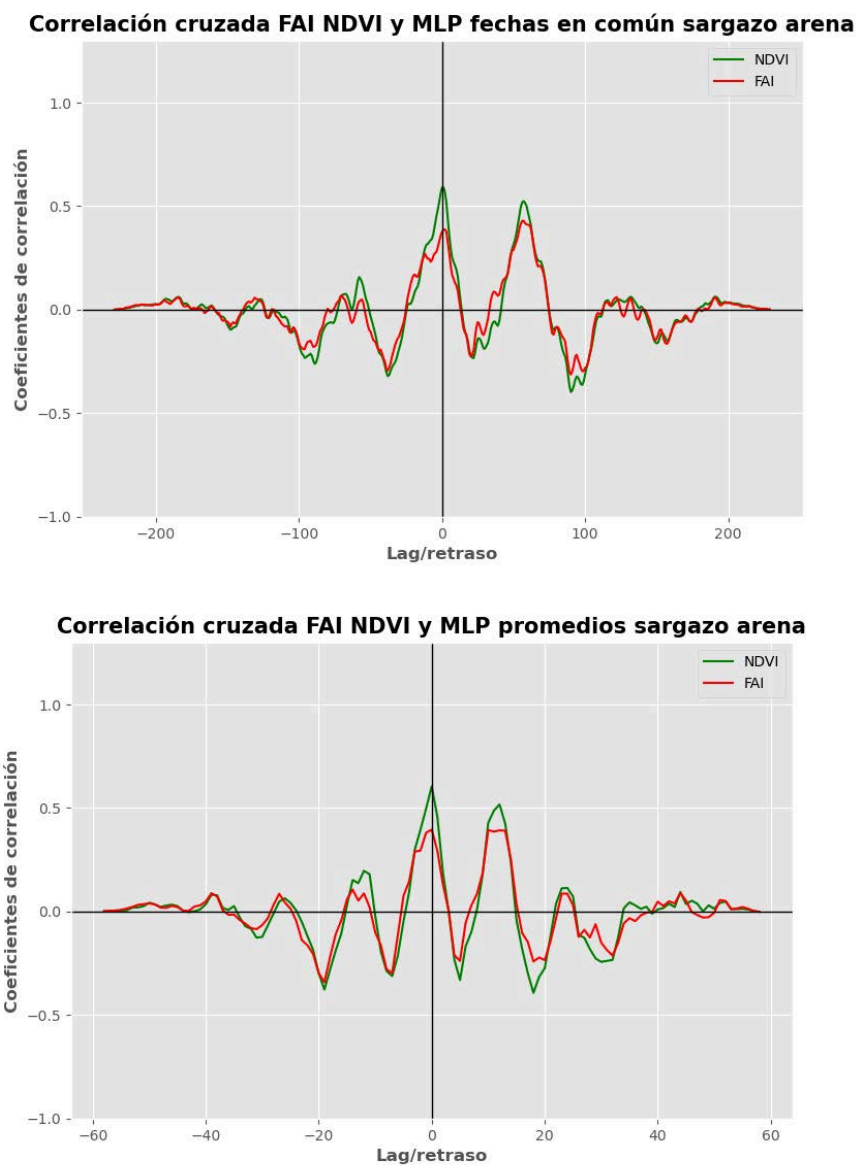


Figura 7.14 Diagramas de correlación cruzada, para las series de tiempo de sargazo en arena.

7.3.2.2 Análisis visual de las series de tiempo

En esta sección, se realiza un análisis visual de las series de tiempo. La figura 7.15 muestra tres series: en azul, la serie correspondiente a la densidad de píxeles detectados como sargazo, la cual corresponde a los valores predichos con RNA MLP; en verde, la serie temporal del promedio de NDVI; y en rojo, la del promedio de FAI. Se resaltan en rojo las secciones donde las series muestran comportamientos diferentes y en verde las secciones donde presentan comportamientos similares. Aunque existen otras áreas de las series de tiempo con patrones similares o diferentes, se seleccionaron solo las más notorias. A continuación, se describen estas secciones.




Figura 7.15 Series de tiempo de fechas en común, hasta arriba en azul está la serie de tiempo creada a partir de la densidad de píxeles detectados en las fotografías a partir de la RNA MLP, en verde la serie de tiempo del promedio de NDVI y en rojo del promedio del FAI.

Secciones diferentes (Rojo):

- En las secciones 1 y 5 de las fotografías, se detectaron cantidades significativamente mayores de sargazo en comparación con lo observado a través de los índices espectrales. En la Figura 7.16 se presenta la fotografía junto con su

imagen satelital correspondiente; sin embargo, el índice no registró el sargazo de manera similar. En el caso de la sección 1, es posible que las condiciones de las algas hayan influido, ya que, al no tratarse de sargazo fresco, el cálculo de los índices resultó en un valor más bajo, aunque aún se observa un pico, aunque menos pronunciado. En el caso de la sección 2, la imagen satelital presenta tonalidades azuladas, lo cual sugiere que podría contener algún error y por lo tanto esto haber provocado la diferencia. Otros factores que pueden generar discrepancias podrían ser: las condiciones atmosféricas, los efectos de los reflejos del agua, la presencia de nubes residuales, sombras, entre otras.




Figura 7.16 Algunas de las fotografías que muestran comportamientos contrarios en las series de tiempo. Mientras las fotografías de la EVMC muestran grandes cantidades de sargazo en la arena, los índices espectrales muestran lo contrario.

Secciones similares:

- Las secciones 2 y 4 se caracterizan por la detección de grandes cantidades de sargazo en las tres series de tiempo. En la figura 7.17 se presentan las fotografías correspondientes a estas fechas: a la izquierda se muestra la imagen original, mientras que a la derecha aparece la fotografía con los píxeles detectados como sargazo (resaltados en rojo). Estas imágenes confirman la elevada presencia de sargazo durante esos periodos.

Sección 2



Sección 4



Figura 7.17 Fotografías en las cuales se detectó gran cantidad de sargazo, tanto en las imágenes satelitales con los índices como en las fotografías de la EVMC. Del lado derecho se encuentra la imagen original, en medio la imagen con la detección de sargazo en rojo y del lado izquierdo su imagen satelital correspondiente.

- En la sección 3, las tres series de tiempo detectan poca cantidad de sargazo. En la figura 7.18 se muestra la fotografía correspondiente a la fecha con menor cantidad de sargazo de este intervalo de fechas, y se puede confirmar que hay muy poco sargazo.



Figura 7.18 Fotografía en la cual se detectó poca cantidad de sargazo en las tres series de tiempo. Del lado izquierdo se muestra la imagen original, en medio la imagen con la detección del sargazo en rojo, y del lado izquierdo su imagen satelital correspondiente.

- En la sección 6, se observa una similitud en los patrones de las series de tiempo, particularmente entre la red neuronal (RNA) de tipo Perceptrón Multicapa (MLP) y el Índice de Vegetación de Diferencia Normalizada (NDVI). Ambas series presentan dos picos positivos y un pico negativo intermedio. Sin embargo, la magnitud de los picos es diferente, pero el comportamiento es parecido.

7.3.2.3 Descomposición de las series de tiempo

Como pudimos notar las series de tiempo muestran un comportamiento estacional, en el cual, las cantidades de sargazo son mayores, en los meses de verano y menores en el invierno. A partir de esta premisa, surgió la necesidad de descomponer las series y así comparar las diversas partes de estas, sobre todo encontrar la correlación de la tendencia sin el fuerte componente estacional observado. Para esto se utilizó el método aditivo en el cual una serie temporal se define como la suma de sus tres componentes (serie = tendencia + estacionalidad + ruido).

Para la descomposición, sólo se tomaron en cuenta los años 2018, 2019 y 2020 de las series de tiempo con fechas coincidentes. La razón es que estos años, tienen una cantidad de datos satelitales considerable y se tienen los años completos en cuanto a las fotografías.

Para descomponer estas series de tiempo se eligió una ventana de tiempo anual, que era equivalente a 62 datos por año. La descomposición se muestra graficada en la figura 7.19.




Figura 7.20 Descomposición de las series de tiempo sargazo en arena, se muestra la tendencia, la estacionalidad y el residuo de RNA MLP, NDVI y FAI.

En cuanto a la tendencia, observamos que las series de tiempo de los índices espectrales muestran una tendencia decreciente. Sin embargo, la serie de sargazo en arena indica que el año con mayor cantidad de píxeles detectados como sargazo fue 2019, aunque esta cantidad va disminuyendo hacia el 2020. En cuanto a la estacionalidad, se identifica un comportamiento anual en las tres series de tiempo analizadas. Sin embargo, esta tendencia sólo corresponde a estos tres años por lo que no significa que esté decreciendo la cantidad de sargazo que llega en los arribazones, esto será discutido a profundidad posteriormente.

7.3.3 Series de tiempo de la detección del sargazo en agua.

De igual manera que para el sargazo en arena, se analizaron las series de tiempo obtenidas a partir de los índices espectrales NDVI y FAI. Como la serie de tiempo de la densidad de píxeles detectados como sargazo con el RF. Primeramente, se va a calcular la correlación, posteriormente se va a realizar un análisis visual y finalmente la descomposición de las series temporales.




Figura 7.20 Series de tiempo adaptadas para tener el mismo número de datos. En este caso son las series generadas a partir del promedio por mes.




Figura 7.21 Series de tiempo adaptadas para tener el mismo número de datos en este caso son las series de tiempo en las cuales corresponden las fechas de la imagen satelital y la fotografía.

7.3.3.1 Cálculo de la correlación.

De igual manera que en la detección del sargazo en arena se analizaron las series de tiempo del sargazo en agua. La figura 7.20 corresponde a las series de tiempo realizadas a partir de los promedios por mes, mientras que en la figura 7.21 se muestran las series de tiempo creadas con las fechas en común. En azul se visualiza la serie de tiempo de densidad de pixeles con RF mientras que el NDVI se visualiza en verde y el FAI en rojo.

En cuanto al sargazo en agua, como vimos en la sección 7.3, se observaba una relación lineal entre las variables por lo que el coeficiente de Pearson es más adecuado para describir la relación.

El valor de correlación de Pearson más alto fue 0.753 que corresponde a la serie de NDVI con RF promedios del mes. En segundo lugar, el valor de correlación de 0.734 que se calculó con las series de tiempo creadas a partir de fechas en común y NDVI. Como en el sargazo en arena, aquí también se encontró una correlación más grande entre NDVI y nuestros valores calculados de Random Forest, que con los del FAI.

En cuanto a los valores FAI hay una correlación positiva de 0.689 en la serie hecha por los promedios y de 0.6488 en la serie con las fechas en común, lo que sugieren una correlación positiva entre FAI y las series de RF a comparación de las series de tiempo de sargazo en arena, donde no hay una correlación. Que los valores de correlación con FAI en la detección del sargazo en agua sean mayores que los del sargazo en arena, puede deberse principalmente porque FAI fue creado para detectar algas en agua, todos estos resultados pueden verse en la tabla 7.7.

En cuanto a los valores de P, al igual que el sargazo en arena, son muy bajos por lo que podemos confirmar que nuestros resultados son estadísticamente significativos.

Tabla 7.7 Coeficientes de correlación de Spearman entre las series de tiempo para la detección de sargazo en agua.

Coeficiente de correlación		Random Forest con			
		Coeficiente Spearman		Coeficiente Pearson	
		NDVI	FAI	NDVI	FAI
Fechas en común	Stat	0.712	0.648	0.734	0.689
	Valor P	6.83e-37	4.12e-29	2.55e-40	4.98e-34
Promedio por mes	Stat	0.727	0.671	0.753	0.736
	Valor P	1.18e-09	0.00012	7.89e-16	4.67e-11

- Correlación cruzada

Como en el caso del sargazo en arena, también se realizó un análisis de correlación cruzada en las series de tiempo con fechas comunes. Para RF vs NDVI, el valor máximo de correlación se encontró en el lag 0, con un valor de 0.734, mientras que para RF vs FAI, el valor máximo también se ubicó en el lag 0, con un valor de 0.689. Por otro lado, al analizar las series de tiempo promediadas por mes, se observó que el valor de correlación más alto para RF vs NDVI fue de 0.7830, y para RF vs FAI fue de 0.7358, ambos en el lag 0. Estos resultados coinciden con los valores de correlación de Pearson obtenidos previamente, lo que refuerza la consistencia de los resultados.




Figura 7.22 Diagramas de correlación cruzada, para las series de tiempo de sargazo en agua.

7.3.3.2 Análisis visual de las series de tiempo

De igual manera que en la arena se hizo un análisis de las secciones en las cuales las series de tiempo son parecidas o diferentes. En azul se muestra la serie de tiempo correspondiente a Random Forest, en verde NDVI y en rojo FAI (figura 7.23).




Figura 7.23 Series de tiempo de fechas en común, hasta arriba en azul está la serie de tiempo creada a partir de la densidad de pixeles detectados en las fotografías a partir de la RF, en verde la serie de tiempo del promedio de NDVI y en rojo del promedio del FAI.

Secciones diferentes:

- La sección 3, en esta sección los índices marcan una cantidad alta de sargazo en el agua, pero eso no se refleja en el agua, al ver la imagen satelital se ve un poco azulada (figura 7.24), quizá debido a una nube residual o alguna otra falla de la imagen. Sin embargo, la plataforma GEE mantuvo esta foto a pesar del filtro de nube.



Figura 7.24 Fotografía VMC del 28/12/2018 del lado derecho con la imagen satelital correspondiente del lado izquierdo.

Secciones similares:

- Las secciones 2, 4 y 5 son partes de las series de tiempo en las cuales todas las series, registraron cantidades altas de sargazo como se muestra en la figura 7.25




Figura 7.25 Fotografías donde se registraron altas cantidades de sargazo, del lado derecho se ve la imagen original y en medio la fotografía con los pixeles detectados en rojo y del lado izquierdo se ve la imagen satelital

- En las secciones 1 y 6 en las series de tiempo se detectó poca cantidad de sargazo, en la figura 7.26 se muestran los ejemplos de las fotografías correspondientes a estas fechas y donde efectivamente se ve poca o nula cantidad de sargazo en el agua.




Figura 7.26 Fotografías donde se registraron pocas cantidades de sargazo del lado izquierdo y del lado derecho su imagen satelital correspondiente.

7.3.3.3 Descomposición de las series de tiempo

De igual manera que en la arena se hizo una descomposición de series de tiempo, utilizando los años 2018, 2019 y 2020 y con la misma estacionalidad de 62 días, las gráficas se pueden ver en la figura 7.27.

En cuanto a la tendencia se ve un comportamiento decreciente, en las tres series de tiempo, aunque a diferencia de los índices espectrales, las series de tiempo de las fotografías muestran ligeramente más sargazo en el 2019. De igual manera podría parecer que la cantidad del sargazo va disminuyendo con el tiempo pero hay que recordar que estas series solo corresponden a una porción pequeña de la playa, esto se discutirá en la discusión de esta tesis. En cuanto a la estacionalidad, se identifica también este patrón anual con altas cantidades de sargazo en los meses de verano y menores en invierno.




Figura 7.27 Descomposición de las series de tiempo sargazo en arena, se muestra la tendencia, la estacionalidad y el residuo de RNA MLP, NDVI y FAI.

7.3.3.4 Deformación temporal dinámica.

Finalmente, para comparar las distintas series de tiempo, se calcularon las distancias entre ellas utilizando Dynamic Time Warping (DTW). A diferencia de la correlación cruzada, DTW permite cuantificar la similitud entre series de tiempo incluso cuando no tienen la misma cantidad de puntos. Se calcularon las distancias en las series originales, es decir, aquellas a las que no se les aplicó ningún procedimiento para igualar la cantidad de datos. En la tabla 7.8 se muestran los resultados de las distancias calculadas. En todos los casos, la menor distancia se obtuvo al comparar las series con el NDVI en lugar del FAI, tanto en sargazo en agua como en sargazo sobre arena. Además, las series de sargazo en agua presentaron distancias menores, lo que sugiere que son más similares entre sí.

Tabla 7.8 Distancias calculadas entre los pares de series de tiempo con DTW.

Sargazo en arena	NDVI	FAI
Series originales	14.820	15.294
Fechas en común	7.273	8.119
Promedios	3.433	3.751

Sargazo en agua	NDVI	FAI
Series originales	11.538	11.975
Fechas en común	5.260	5.552
Promedios	3.792	3.500

Estos valores de distancia comprueban nuestros resultados anteriores, en los cuales hay más similitud en las series de las EVMC con el NDVI y que además hay mayor similitud con las series de sargazo en agua que con las de sargazo en arena.

7.3.4 Comparación con registros anteriores.

Con el objetivo de validar nuestros resultados, se compararon las detecciones y series de tiempo con otros registros, en este caso se comparan las series de tiempo de sargazo en agua y arena promedio de las fotografías con los resultados que registra Chávez et al., 2020 quienes reportan cantidades de sargazo en Puerto Morelos utilizando imágenes Landsat 8 y además reportan las cantidades de sargazo removidas por hoteles en la zona norte del Caribe mexicano (datos proporcionados por nueve hoteles). En la figura 7.28 se acomodaron las series de tiempo de esta tesis, así como también las de Chavez et al., 2020, con el objetivo de comparar los comportamientos de las series.

En su artículo menciona que la cantidad de sargazo máxima se registró en septiembre del 2018 y en abril del 2019. En las series de tiempo de detección de sargazo en agua de las fotos también se ve un máximo en septiembre, pero en el 2019 se registra más bien en junio. En cuanto a la serie de tiempo de arena también se registran altas cantidades de sargazo en esos mismos dos periodos, pero el máximo se registra en julio del 2019.

En cuanto a los mínimos en el artículo mencionan dos periodos: Del año 2016 al 2017 y de noviembre de 2019 a abril de 2020. También Chávez et al. menciona que, en 2020, la cobertura de sargazo fue prácticamente nula hasta que se detectaron las primeras matas de sargazo en mayo, aumentando en julio (6500 ha) y luego cayendo en agosto. Lo que coincide con nuestros resultados.




Figura 7.28 a) Series de tiempo de nuestro trabajo correspondiente a las detecciones de sargazo en agua, b) Detecciones de sargazo en arena en fotografías de EVMC, c) serie de tiempo de detección de sargazo utilizando imágenes Landsat 8 , d) serie de tiempo de cantidades de sargazo removidas por los hoteles. Estas dos últimas series de tiempos fueron tomadas de Chávez et al., 2020.

Sin embargo, son notorias algunas diferencias, en especial las series generadas a partir de la EVMC registran más periodos con altas cantidades de sargazo, sobre todo en los años 2018 y 2019 de abril a octubre a comparación con las series de Chavez. En cuanto a la tendencia, Chávez et al., menciona en su artículo una tendencia decreciente, lo cual corresponde con la detección de sargazo en agua.

A pesar de las diferencias, también se observan algunas similitudes entre las series de tiempo. Es importante destacar que las detecciones de sargazo corresponden a una sección reducida de la playa en Puerto Morelos, mientras que su estudio abarca toda la zona de Puerto Morelos.

7.4 Limitaciones en la detección del sargazo en las fotografías.

A partir de todos estos resultados, fue necesario poner esta sección en la cual discuten las limitaciones encontradas al detectar el sargazo en las fotografías de la EVMC. Algunas de estas limitaciones fueron:

- Malas condiciones climáticas, temporadas de lluvia o de huracanes las cuales ensucian la cámara (Figura 7.29 a y b). También las condiciones nubladas de luz dificultan la detección del sargazo en la arena ya que, con esas condiciones de luz, los colores de la vegetación con el sargazo en arena se ven similares (Figura 7.29 c y d)




Figura 7.29. a) y b) Fotografías en las cuales la cámara se veía sucia, con gotas, después de una lluvia. En la fotografía c y d se muestra una fotografía en la cual es difícil distinguir el sargazo en la arena de la vegetación.

- Días en los cuales el sargazo en el agua estaba más revuelto haciéndolo difícil de detectar, como se observan en las fotografías de la figura 7.30.



Figura 7.30 Fotografías donde el sargazo en el agua estaba revuelto.

- Otros elementos: como objetos tales como: pájaros, lanchas y personas los cuales se detectan como sargazo en algunas fotografías (figura 7.31).



Figura 7.31 Ejemplos de fotografías donde se detectaron algunos pixeles como sargazo pero eran personas.

Estas fueron las principales limitaciones que se identificaron al detectar el sargazo en las fotografías, y las cuales causaron falsos positivos en estas imágenes.

8. DISCUSIÓN Y CONCLUSIONES

8.1 Detección del sargazo en fotografías utilizando algoritmos de Aprendizaje Automático

En esta tesis se ha demostrado que es posible emplear imágenes fotográficas para la detección y monitoreo del sargazo mediante el uso de algoritmos de Aprendizaje Automático, entre los que se incluyen SVM, Random Forest y una Red Neuronal Artificial de Perceptrón Multicapa (MLP). Se evaluó la detección en dos entornos distintos: sargazo en arena y sargazo en agua. A continuación, se presentan la discusión y conclusión para cada caso:

8.1.1 Sargazo en arena

Para el entrenamiento del modelo de detección de sargazo en arena, se realizó un análisis de las características basado en el criterio de impureza de Gini, así como también un análisis de las distribuciones de las características en diferentes medios. Los cuatro atributos más importantes resultaron ser los componentes de color RGB y el Value, siendo el canal Green el que mayor peso tuvo en la clasificación. Esto podría explicarse porque el verde ayuda a distinguir la vegetación del sargazo, ya que la vegetación tiende a tener tonalidades más saturadas en este canal. Por otro lado, el Value o brillo también fue una característica clave, esto puede deberse a que la arena presenta valores de brillo claramente más altos en comparación con el sargazo y otros elementos.

Nuestro mejor modelo para la detección de sargazo en arena resultó ser la Red Neuronal Perceptrón Multicapa (MLP), alcanzando un rendimiento superior al 0.86 tanto en el valor de puntuación F1 como en el de exactitud. Las redes neuronales han demostrado ser particularmente exitosas en la resolución de problemas no lineales, y su arquitectura de múltiples capas permite aprender patrones complejos en los datos, lo que explica su rendimiento superior en este problema. Sin embargo, los modelos de Random Forest y SVM con núcleo RBF obtuvieron exactitudes muy cercanas, con valores superiores al 0.83. El algoritmo que presentó el peor rendimiento fue el SVM con kernel lineal, con valores de rendimiento de alrededor de 0.75. Esto puede atribuirse a que un hiperplano lineal no fue capaz de separar eficazmente las clases de sargazo y no sargazo, en comparación con los algoritmos más flexibles que no están limitados por la linealidad.

8.1.2 Sargazo en agua

En cuanto a la detección de sargazo en agua, el análisis de características reveló que el componente de color Hue es el más relevante en comparación con otras características, seguido por el valor de Blue, Red, Value y la saturación. La relevancia de Hue se debe, probablemente, a que esta característica de color distingue diferencias de color sutiles ya que organiza el color en términos del matiz en lugar de en tres canales separados, como lo hace el espacio RGB, donde cada color se representa como una combinación de valores en

rojo, verde y azul. Por lo que, en este caso, donde el sargazo contrasta con el agua de una manera más sutil que el sargazo con respecto a la arena, Hue se convierte en una característica clave para diferenciar el sargazo. La siguiente característica resultó ser el Blue (azul), lo que también tiene mucho sentido, ya que el agua es el medio donde se encuentra el sargazo mojado y de el cual se tiene que distinguir.

La detección de sargazo en agua representa una tarea más complicada a comparación del sargazo en arena, ya que incluso para el ojo humano es difícil distinguirlo, debido a que no se diferencia significativamente del color del agua. Además, la mezcla del sargazo con el agua y los reflejos en la superficie complican aún más su identificación, esto se ve reflejado en el rendimiento del modelo comparado al del sargazo en arena. En este escenario, el modelo con mejor rendimiento fue el Random Forest, con un valor F1 superior a 0.72 y una exactitud de 0.76, tanto en la validación cruzada como en la evaluación con el conjunto de datos de test. Sin embargo, los modelos de RNA y SVM RBF obtuvieron valores de rendimiento muy similares al Random Forest. El único modelo diferente, como en el caso del sargazo en agua fue el SVM lineal.

8.1.3 Discusión de la detección en ambos métodos.

Durante el entrenamiento y la evaluación de los modelos se observaron otros aspectos relevantes, tales como los tiempos de predicción y la viabilidad de emplear un solo modelo para detectar sargazo en ambos medios. Además, se revisaron otros factores que se detallan en esta subsección.

En cuanto a los tiempos de predicción, la red neuronal y el SVM con kernel RBF fueron los modelos que tomaron más tiempo en la fase de entrenamiento, pero resultaron tener altas métricas en la predicción. En el caso de el kernel RBF fue significativamente lento durante la predicción, llegando a tardar hasta cien veces más en comparación con los otros algoritmos. Esto se debe probablemente a que el kernel RBF para hacer una predicción en vez de calcular solo producto escalar como en el caso del SVM lineal, hay que calcular una exponencial y una norma euclidiana para cada vector de soporte. Al igual que en la detección de sargazo en arena, el SVM lineal fue el algoritmo más rápido de entrenamiento sin embargo tuvo el menor rendimiento en ambos medios. Esto se debe a la misma razón mencionada previamente: un modelo lineal no es lo suficientemente flexible ni robusto para separar de manera efectiva las clases de sargazo y no sargazo.

Adicionalmente, se consideró pertinente evaluar la posibilidad de utilizar sólo un modelo para detectar el sargazo en ambos medios, para esto se utilizó cada modelo para predecir en el medio contrario, es decir, el modelo entrenado para la detección de sargazo en arena se aplicó para predecir sargazo en agua, y viceversa. Los resultados mostraron una disminución considerable en el rendimiento en ambos modelos. El modelo ganador en arena, la red neuronal MLP, predijo sargazo en agua con un valor de puntuación F1 de 0.58, mientras que el modelo específico para agua logró exactitudes superiores a 0.72. De manera similar, el modelo para agua, Random Forest, predijo sargazo en arena con una exactitud de 0.82, comparado con una exactitud de 0.88 del modelo entrenado

específicamente para arena. Esto podría confirmar la hipótesis de que es necesario crear un modelo específico para cada medio, ya que esto mejora significativamente la exactitud y el rendimiento de los algoritmos, especialmente en la detección de sargazo en agua, que resulta particularmente difícil de predecir. Sin embargo también se podrían haber realizado más pruebas para comprobar plenamente esta hipótesis.

También es necesario comentar que para el entrenamiento de los algoritmos de Aprendizaje automático fue esencial llevar a cabo los dos siguientes procesos:

- Se determinó la necesidad de crear máscaras para delimitar la región de interés y ocultar estructuras de color similar al sargazo. Sin una máscara, la detección se hubiese complicado más, debido a distintos elementos que se confunden con el sargazo y así disminuyendo el rendimiento de nuestros modelos. Además, el costo computacional hubiese sido mucho más alto. Este punto resalta la importancia de tener una playa despejada para facilitar la detección de ciertos fenómenos o elementos costeros, lo cual debería considerarse para la instalación de futuras EVMC.
- Otro aspecto importante en la metodología de detección de sargazo fue buscar una forma de homogeneizar las condiciones de las fotografías que, al ser tomadas cada hora, tenían condiciones de luz muy diferentes. Esto se hizo a partir de encontrar las mejores horas para detectar el sargazo, que resultaron ser de las 12:00 a las 16:00 horas.

8.2 Análisis de series de tiempo

Al comparar visualmente las series de tiempo generadas a partir del promedio de índices espectrales con las series de tiempo derivadas de la densidad de píxeles en las fotografías costeras, se observan similitudes notables. Todas las series muestran un comportamiento estacional anual, así como una detección mayor de sargazo durante los meses de verano.

Para cuantificar la relación entre estas series de tiempo, se calcularon los coeficientes de correlación de Spearman y de Pearson. En algunos casos, estas correlaciones resultaron ser más altas que en otros, lo que nos ayuda a resaltar tanto las similitudes como las diferencias entre los dos métodos:

En el caso de la detección de sargazo en arena, las series temporales muestran correlaciones mayores a 0.60. Lo que sugiere una correlación positiva moderada. Se encontró una correlación más fuerte entre la serie generada por la red neuronal MLP y el índice NDVI, en comparación con el índice FAI. Esto es de esperarse, dado que el índice FAI no fue diseñado para detectar sargazo en arena, sino que se basa en la diferencia de reflectancia entre el agua y el alga.

En cuanto a la detección de sargazo en agua, los coeficientes de correlación son más altos, con valores superiores a 0.7 en relación con el NDVI. lo que indican una correlación positiva fuerte. Para el índice FAI, los valores oscilan entre 0.68 y 0.7 lo que indica una correlación fuerte positiva. Esto es consistente con el propósito original del FAI, que fue creado específicamente para detectar sargazo en agua. Sin embargo, la correlación del FAI es ligeramente menor en comparación con la del NDVI, lo cual podría deberse, como señala

Hu (2009), a que el FAI es muy sensible a las aguas turbias y a las zonas de poca profundidad.

En cuanto a la descomposición de las series de tiempo, ambos métodos, tanto las fotografías como los índices espectrales, revelan una estacionalidad anual ya observada anteriormente. Respecto a la tendencia, las series de tiempo del sargazo en arena presentan ligeras diferencias entre las fotografías y los índices: en las fotografías, el año con mayor acumulación de sargazo es 2019, mientras que en los índices el año pico es 2018. No obstante, esta diferencia no es muy marcada, y en ambos métodos se observa una aparente disminución de sargazo hacia el año 2020. En las series de tiempo del sargazo en agua, todas muestran una tendencia decreciente.

Es importante destacar que, aunque esta tendencia señala una posible reducción en la cantidad de sargazo, aplica únicamente a una sección de la playa y abarca un periodo limitado de tres años, de 2018 a 2020, lo cual puede dar la impresión de una disminución general. Sin embargo, en años posteriores, como en 2023, se han registrado arribazones de sargazo superiores a las de años anteriores (Lindsey, 2023).

8.3 Ventajas y desventajas de imágenes satelitales y video monitoreo costero.

A partir de esta tesis, se demuestra que las fotografías obtenidas a través de EVMC son eficaces para monitorear el sargazo, ya que ofrecen una resolución espacial y temporal mucho mejor que las imágenes satelitales gratuitas, como las proporcionadas por Sentinel-2.

Una de las principales ventajas de las fotografías es la facilidad con la que se puede evaluar la cantidad de sargazo, ya que es posible revisar visualmente la imagen para validar la detección. En cambio, las imágenes satelitales requieren el cálculo de un índice espectral, y su menor resolución espacial dificulta la visualización detallada del sargazo. Además, las fotografías permiten un control más preciso de los elementos presentes en la imagen debido a su alta resolución, lo que facilita la creación de máscaras detalladas para eliminar objetos que podrían generar confusión, algo que no es posible con las imágenes satelitales de acceso libre debido a su resolución. Otra ventaja de las fotografías es que, aunque las condiciones atmosféricas pueden afectar su calidad, lo hacen en menor medida que en las imágenes satelitales, que dependen en gran medida de las condiciones meteorológicas para el cálculo de los índices espectrales y otros métodos de procesamiento remoto.

Por otro lado, una de las desventajas de las fotografías es la variabilidad en las condiciones de iluminación y color a lo largo del día, lo cual afecta la consistencia de las imágenes. Por ello, resulta fundamental, como se hizo en este trabajo, seleccionar horarios óptimos para la captura de fotografías o implementar métodos que homogenicen la luz en las imágenes. Además, las condiciones climáticas adversas, como lluvias o huracanes, pueden ensuciar las cámaras y deteriorar la calidad de las imágenes, y la luz nublada tiende a dificultar la detección del sargazo tanto en la arena, ya que los colores de la vegetación y el sargazo se

asemejan bajo estas condiciones, como en el agua donde el mar aparece de un color morado así como también el sargazo y de igual manera es difícil de diferenciar. Otros elementos en las fotografías, como pájaros, lanchas o personas, también pueden ser detectados erróneamente como sargazo, afectando así la precisión de la detección.

En cuanto a las imágenes satelitales, una ventaja significativa sobre las fotografías es que las cámaras solo cubren una parte muy limitada de la playa, lo que limita el seguimiento y la capacidad de prever la llegada del sargazo. Las imágenes satelitales, por su parte, ofrecen una cobertura amplia que permite monitorear el fenómeno antes de que el sargazo llegue a la playa, proporcionando información valiosa para la prevención. Mientras que las fotografías son más útiles para registrar las cantidades de sargazo acumulado, facilitando la creación de series temporales y la gestión de la limpieza, por otro lado las imágenes satelitales ayudan en la prevención y en el seguimiento a gran escala del fenómeno.

Otra ventaja importante de las imágenes satelitales es que, mediante herramientas como Google Earth Engine, es muy sencillo acceder a imágenes ya corregidas, delimitar la región de interés (ROI) y calcular índices espectrales. En contraste, las fotografías requieren un preprocesamiento más extenso, así como el etiquetado y entrenamiento de un modelo de detección de sargazo, lo cual consume mucho más tiempo. Sin embargo, como se ha demostrado en esta tesis, una vez que el modelo ha sido entrenado, es rápido y eficiente obtener estimaciones de la cantidad de sargazo en la playa a partir de las fotografías.

8.4 Trabajo a futuro

El hecho de que las detecciones de ambas fuentes de datos (fotografías y datos satelitales) se correlacionen positivamente y que sus series de tiempo muestran comportamientos similares sugiere la posibilidad de fusionar distintos métodos con diferentes escalas espaciales y temporales en futuros estudios. Esto abre la puerta al desarrollo de una metodología integrada que combine estos enfoques para un monitoreo y alerta más eficaces del sargazo, algo que no se abordó en este trabajo, donde simplemente se calcularon y analizaron las detecciones de ambas fuentes de manera independiente, pero no se generó una metodología que permita conjuntar las dos detecciones.

Asimismo, es importante señalar que en este trabajo no se calibraron las imágenes, lo que es altamente recomendable. La falta de calibración se debe a la ausencia de información relevante, lo que representa una limitación significativa. Con una calibración adecuada, se podría obtener una correlación más precisa entre las diferentes fuentes de datos, permitiendo una comparación más robusta en futuras investigaciones.

Además, considero que faltó una comparación de estos resultados con datos provenientes de iniciativas de ciencia ciudadana o mapeo comunitario. La integración de información recolectada directamente en la zona, como la cantidad de sargazo recolectado por hoteles o entidades gubernamentales, así como los aportes de la comunidad local, podría enriquecer considerablemente los análisis y proporcionar una visión más amplia y contextualizada del fenómeno.

8.5 Conclusión general

A partir de este análisis, se puede concluir que el uso de fotografías de video monitoreo costero junto con modelos de Aprendizaje Automático es una herramienta valiosa tanto para el monitoreo como para la gestión del sargazo.

Otro hallazgo importante es que, a pesar de que se miden variables distintas, las detecciones provenientes de ambas fuentes de datos (fotografías y datos satelitales) se correlacionan positivamente, y sus series de tiempo reflejan comportamientos similares. Esto demuestra la efectividad de ambos métodos en la detección del sargazo.

Por lo tanto, a pesar de las desventajas previamente discutidas de estos dos métodos, se puede afirmar que ambos enfoques son importantes y complementarios para la detección y monitoreo del sargazo. Al mismo tiempo, las fotografías, al ofrecer una mayor resolución y detalle, son útiles para la cuantificación precisa y la gestión del sargazo ya asentado en la costa, lo que facilita la toma de decisiones para su limpieza y aprovechamiento.

Al complementar ambos métodos, se puede obtener un monitoreo del sargazo más eficiente que permita minimizar los daños tanto económicos como ecológicos relacionados con las llegadas masivas del sargazo, al prevenir los arribazones, así como también gestionar los recursos para la recolección del mismo.

REFERENCIAS

- Arellano-Verdejo, J., Lazcano-Hernandez, H. E., & Cabanillas-Terán, N. (2019). ERISNet: deep neural network for Sargassum detection along the coastline of the Mexican Caribbean. *PeerJ*, 7, e6842.
- Arellano-Verdejo, J., & Lazcano-Hernández, H. E. (2021). Collective view: mapping Sargassum distribution along beaches. *PeerJ Computer Science*, 7, e528.
- Arellano-Verdejo, J., Santos-Romero, M., & Lazcano-Hernandez, H. E. (2022). Use of semantic segmentation for mapping Sargassum on beaches. *PeerJ*, 10, e13537.
- Atkinson, P. M., & Tatnall, A. R. (1997). Introduction neural networks in remote sensing. *International Journal of remote sensing*, 18(4), 699-709.
- Ali, I.; Rehman, A.U.; Khan, D.M.; Khan, Z.; Shafiq, M.; Choi, J.-G. Model Selection Using K-Means Clustering Algorithm for the Symmetrical Segmentation of Remote Sensing Datasets. *Symmetry* 2022, 14, 1149.
- Bauer, E., & Kohavi, R. (1999). An empirical comparison of voting classification algorithms: Bagging, boosting, and variants. *Machine learning*, 36, 105-139.
- Bhardwaj, A., Di, W., & Wei, J. (2018). *Deep Learning Essentials: Your hands-on guide to the fundamentals of deep learning and neural network modeling*. Packt Publishing Ltd.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brignone, M., Schiaffino, C. F., Isla, F. I., & Ferrari, M. (2012). A system for beach video-monitoring: Beachkeeper plus. *Computers & geosciences*, 49, 53-61.
- Brownlee, J. (2019). How to choose a feature selection method for machine learning. *Machine Learning Mastery*, 10, 1-7.
- Bourke, P. (1996). Cross correlation. *Cross Correlation”, Auto Correlation—2D Pattern Identification*, 596.
- Butler, J.N., B.F. Morris, J. Cadwallader and A.W. Stoner. (1983). Studies of Sargassum and the Sargassum community. Bermuda Biological Station Research, Special Publication 22: 1-307.
- Chandler, C. J., Ávila-Mosqueda, S. V., Salas-Acosta, E. R., Magaña-Gallegos, E., Mancera, E. E., Reali, M. A. G., ... & Foody, G. M. (2023). Spectral Characteristics of Beached Sargassum in Response to Drying and Decay over Time. *Remote Sensing*, 15(17), 4336.
- Chávez, V., Uribe-Martínez, A., Cuevas, E., Rodríguez-Martínez, R. E., Van Tussenbroek, B. I., Francisco, V., ... & Silva, R. (2020). Massive influx of pelagic Sargassum spp. on the

coasts of the Mexican Caribbean 2014–2020: Challenges and opportunities. *Water*, 12(10), 2908.

Coronado, C., Candela, J., Iglesias-Prieto, R., Sheinbaum, J., López, M., & Ocampo-Torres, F. J. (2007). On the circulation in the Puerto Morelos fringing reef lagoon. *Coral Reefs*, 26, 149-163.

Cuevas, E., Uribe-Martínez, A., & Liceaga-Correa, M. D. L. Á. (2018). A satellite remote-sensing multi-index approach to discriminate pelagic *Sargassum* in the waters of the Yucatan Peninsula, Mexico. *International Journal of Remote Sensing*, 39(11), 3608-3627.

Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random forests. *Ensemble machine learning: Methods and applications*, 157-175.

Dalianis, H., & Dalianis, H. (2018). Evaluation metrics and evaluation. *Clinical Text Mining: secondary use of electronic patient records*, 45-53.

Elachi, C., & Van Zyl, J. J. (2021). *Introduction to the physics and techniques of remote sensing*. John Wiley & Sons.

Devault, D. A., Pierre, R., Marfaing, H., Dolique, F., & Lopez, P. J. (2021). *Sargassum* contamination and consequences for downstream uses: a review. *Journal of Applied Phycology*, 33, 567-602.

Djakouré, S., Araujo, M., Hounsou-Gbo, A., Noriega, C., & Boulès, B. (2017). On the potential causes of the recent Pelagic *Sargassum* blooms events in the tropical North Atlantic Ocean. *Biogeosciences Discussions*, 2017, 1-20.

Espinoza, L. A., & Li, J. (2020). El riesgo del sargazo para la economía y turismo de Quintana Roo y México. *BBVA Research*, 20, 2-33.

Franks, J. S., Johnson, D. R., & Ko, D. S. (2016). Pelagic *sargassum* in the tropical North Atlantic. *Gulf and Caribbean Research*, 27(1), SC6-SC11.

Foody, G. M., Aragon, H., De la Barrera-Bautista, B., Boyd, D. S., Estrada, S. C., Lopez, P., ... & Smith, G. (2021, July). Developing a system to map and monitor beached *sargassum* on the Caribbean coast of Mexico. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS* (pp. 2432-2435). IEEE.

Govender, M., Chetty, K., & Bulcock, H. (2007). A review of hyperspectral remote sensing and its application in vegetation and water resource studies. *Water Sa*, 33(2), 145-151.

Gower, J., Hu, C., Borstad, G., & King, S. (2006). Ocean color satellites show extensive lines of floating *Sargassum* in the Gulf of Mexico. *IEEE Transactions on Geoscience and Remote Sensing*, 44(12), 3619-3625.

Gower, J., & King, S. (2008). Satellite images show the movement of floating *Sargassum* in the Gulf of Mexico and Atlantic Ocean. *Nature Precedings*, 1-1.

Gower, J., Young, E., & King, S. (2013). Satellite images suggest a new Sargassum source region in 2011. *Remote Sensing Letters*, 4(8), 764-773.

Gower, J., & King, S. (2020). The distribution of pelagic Sargassum observed with OLCI. *International Journal of Remote Sensing*, 41(15), 5669-5679.

Harmon, M. E., & Harmon, S. S. (1996). Reinforcement learning: A tutorial. WL/AAFC, WPAFB Ohio, 45433, 237-285.

Hassan, M. R., Ema, R. R., & Islam, T. (2017). Color image segmentation using automated K-means clustering with RGB and HSV color spaces. *Global Journal of Computer Science and Technology*, 17(2), 25-33.

Hasselt, H. (2011). *Insights in reinforcement learning*. Hado van.

Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Vol. 2, pp. 1-758). New York: springer.

Hema, D., & Kannan, D. S. (2019). Interactive color image segmentation using HSV color space. *Sci. Technol. J*, 7(1), 37-41.

Hoonhout, B., de Vries, S., Baart, F., de Vries, J. V. T., van der Weerd, L., & Wijnberg, K. (2013). Monitoring of beach surface properties with remote sensing. In *7th International Conference on Coastal Dynamics, Coastal Dynamics 2013* (pp. 821-832). Bordeaux University-SHOM.

Hossain, E. (2023). *Machine Learning Crash Course for Engineers*. Springer Nature.

Hu, C. (2009). A novel ocean color index to detect floating algae in the global oceans. *Remote Sensing of Environment*, 113(10), 2118-2129.

Hu, C., Feng, L., Hardy, R. F., & Hochberg, E. J. (2015). Spectral and spatial requirements of remote measurements of pelagic Sargassum macroalgae. *Remote Sensing of Environment*, 167, 229-246.

Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32(1), 1-6.

Huffard, C. L., Von Thun, S., Sherman, A. D., Sealey, K., & Smith, K. L. (2014). Pelagic Sargassum community change over a 40-year period: temporal and spatial variability. *Marine Biology*, 161, 2735-2751.

Huljanah, M., Rustam, Z., Utama, S., & Siswantining, T. (2019, June). Feature selection using random forest classifier for predicting prostate cancer. In *IOP Conference Series: Materials Science and Engineering* (Vol. 546, No. 5, p. 052031). IOP Publishing.

Hynninen, P. H., & Leppäkases, T. S. (2002). The functions of chlorophylls in photosynthesis. *EOLSS Oxford UK*, 5, 1-9.

Marín Ivonne, A., M., Zizumbo, L., Gabriel, O., & Lara, H. (2022). CONFLICTOS AMBIENTALES DEL TURISMO EN PUERTO MORELOS, QUINTANA ROO, MÉXICO.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: springer.

Johns, E. M., Lumpkin, R., Putman, N. F., Smith, R. H., Muller-Karger, F. E., Rueda-Roa, D. T., ... & Werner, F. E. (2020). The establishment of a pelagic Sargassum population in the tropical Atlantic: biological consequences of a basin-scale long distance dispersal event. *Progress in Oceanography*, 182, 102269.

Jóia Santos, C., Andriolo, U., & Ferreira, J. C. (2020). Shoreline response to a sandy nourishment in a wave-dominated coast using video monitoring. *Water*, 12(6), 1632.

Jones, H. G., & Vaughan, R. A. (2010). Remote sensing of vegetation: principles, techniques, and applications. Oxford University Press, USA.

Kawakubo, H., & Yoshida, H. (2012). Rapid feature selection based on random forests for high-dimensional data. *Expert Syst. Appl*, 40, 6241-6252.

Kim, E. (2013). Everything you wanted to know about the kernel trick. URI: http://www.eric-kim.net/eric-kim-net/posts/1/kernel_trick.html.

Kodinariya, T. M., & Makwana, P. R. (2013). Review on determining the number of Clusters in K-Means Clustering. *International Journal*, 1(6), 90-95.

Kuo, B. C., Ho, H. H., Li, C. H., Hung, C. C., & Taur, J. S. (2013). A kernel-based feature selection method for SVM with RBF kernel for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 317-326.

Lapointe, B. E. (1995). A comparison of nutrient-limited productivity in Sargassum natans from neritic vs. oceanic waters of the western North Atlantic Ocean. *Limnology and Oceanography*, 40(3), 625-633.

Lazcano-Hernandez, H. E., Arellano-Verdejo, J., & Rodríguez-Martínez, R. E. (2023). Algorithms applied for monitoring pelagic Sargassum. *Frontiers in Marine Science*, 10, 1216426.

Laval, M., Belmouhcine, A., Courtrai, L., Descloitres, J., Salazar-Garibay, A., Schamberger, L., ... & Chevalier, C. (2023). Detection of sargassum from sentinel satellite sensors using deep learning approach. *Remote Sensing*, 15(4), 1104.

Lavender, S., & Lavender, A. (2023). Practical handbook of remote sensing. CRC Press.

Li, J. J., & Du, X. K. (2024). Will climate change cause Sargassum beds in temperate waters to expand or contract? Evidence from the range shift pattern of Sargassum. *Marine Environmental Research*, 200, 106659.

Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.

Lindsey, R. (2023, 20 de abril). La proliferación masiva de algas en el Atlántico tropical aumenta el riesgo de impacto en las playas del Caribe, el Golfo y Florida en los próximos meses. En NOAA Climate.gov. Recuperado de <https://www.aoml.noaa.gov/es/massive-bloom-of-seaweed-in-tropical-atlantic/>.

Loh, W. Y. (2011). Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1), 14-23.

López Miranda, J. L., Celis, L. B., Estévez, M., Chávez, V., van Tussenbroek, B. I., Uribe-Martínez, A., ... & Silva, R. (2021). Commercial potential of pelagic Sargassum spp. in Mexico. *Frontiers in Marine Science*, 8, 768470.

Lovatti, B. P., Nascimento, M. H., Neto, Á. C., Castro, E. V., & Filgueiras, P. R. (2019). Use of Random forest in the identification of important variables. *Microchemical Journal*, 145, 1129-1134.

Magaña-Gallegos, E., Villegas-Muñoz, E., Salas-Acosta, E. R., Barba-Santos, M. G., Silva, R., & van Tussenbroek, B. I. (2023). The effect of temperature on the growth of holopelagic sargassum species. *Phycology*, 3(1), 138-146.

Mendoza-Becerril, M. A., Serviere-Zaragoza, E., Mazariegos-Villarreal, A., Rivera-Perez, C., Calder, D. R., Vázquez-Delfín, E. F., ... & Robledo, D. (2020). Epibiont hydroids on beachcast Sargassum in the Mexican Caribbean. *PeerJ*, 8, e9795.

Michie, D., Spiegelhalter, D. J., Taylor, C. C., & Campbell, J. (Eds.). (1995). *Machine learning, neural and statistical classification*. Ellis Horwood.

Montes, J.; Simarro, G.; Benavente, J.; Plomaritis, T.A.; Del Río, L. Morphodynamics Assessment by Means of Mesofoms and Video-Monitoring in a Dissipative Beach. *Geosciences* 2018, 8, 448.

Myers, L., & Sirois, M. J. (2004). Spearman correlation coefficients, differences between. *Encyclopedia of statistical sciences*, 12.

Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*. b, 4(51-62), 56.

Nguyen, D., Nguyen, C., Duong-Ba, T., Nguyen, H., Nguyen, A., & Tran, T. (2017, January). Joint network coding and machine learning for error-prone wireless broadcast. In *2017 IEEE*

7th Annual Computing and Communication Workshop and Conference (CCWC) (pp. 1-7). IEEE.

Nieto, M. A., Garau, B., Balle, S., Simarro, G., Zarruk, G. A., Ortiz, A., ... & Orfila, A. (2010). An open source, low cost video-based coastal monitoring system. *Earth Surface Processes and Landforms*, 35(14), 1712-1719.

Ody, A., Thibaut, T., Berline, L., Changeux, T., Andre, J. M., Chevalier, C., ... & Menard, F. (2019). From In Situ to satellite observations of pelagic Sargassum distribution and aggregation in the Tropical North Atlantic Ocean. *PLoS One*, 14(9), e0222584.

Osorio, A. F., Medina, R., & Gonzalez, M. (2012). An algorithm for the measurement of shoreline and intertidal beach profiles using video imagery: PSDM. *Computers & Geosciences*, 46, 196-207.

OpenCV. (2024). Background Subtractor MOG. Documentación de OpenCV. https://docs.opencv.org/4.x/d8/d38/tutorial_bgsegm_bg_subtraction.html

Oviatt, C. A., Huizenga, K., Rogers, C. S., & Miller, W. J. (2019). What nutrient sources support anomalous growth and the recent sargassum mass stranding on Caribbean beaches? A review. *Marine pollution bulletin*, 145, 517-525.

Oxenford, H. A., Cox, S. A., van Tussenbroek, B. I., & Desrochers, A. (2021). Challenges of turning the Sargassum crisis into gold: current constraints and implications for the Caribbean. *Phycology*, 1(1), 27-48.

Pandey, A., & Malviya, A. K. (2018). Enhancing test case reduction by k-means algorithm and elbow method. *International Journal of Computer Sciences and Engineering*, 6(6), 299-303.

Pareek, S., Sagar, N. A., Sharma, S., Kumar, V., Agarwal, T., González-Aguilar, G. A., & Yahia, E. M. (2017). Chlorophylls: Chemistry and biological functions. *Fruit and Vegetable Phytochemicals: Chemistry and Human Health*, 2nd Edition, 269-284.

Pelka, P. (2019). Similarity analysis of the patterns of the monthly electric energy demand time series. In *E3S Web of Conferences* (Vol. 84, p. 01008). EDP Sciences.

Pendleton, L., Krowicki, F., Strosser, P., & Hallett-Murdoch, J. (2014). Assessing the economic contribution of marine and coastal ecosystem services in the Sargasso Sea. *Sargasso Sea Alliance Science Report Series*.

Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using Google Earth Engine and random forest classifier—The role of image composition. *Remote Sensing*, 12(15), 2411.

Putman, N. F., Beyea, R. T., Iporac, L. A. R., Triñanes, J., Ackerman, E. G., Olascoaga, M. J., ... & Goni, G. (2023). Improving satellite monitoring of coastal inundations of pelagic Sargassum algae with wind and citizen science data. *Aquatic Botany*, 188, 103672.

Raileanu, L. E., & Stoffel, K. (2004). Theoretical comparison between the gini index and information gain criteria. *Annals of Mathematics and Artificial Intelligence*, 41, 77-93.

Resiere, D., Valentino, R., Nevière, R., Banydeen, R., Gueye, P., Florentin, J., ... & Mehdaoui, H. (2019). Sargassum seaweed on Caribbean islands: an international public health concern. *Lancet (London, England)*, 392(10165), 2691.

Rodríguez-Martínez, R. E., van Tussenbroek, B., & Jordán-Dahlgren, E. (2016). Afluencia masiva de sargazo pelágico a la costa del Caribe mexicano (2014–2015). *Florecimientos Algas Nocivos en México*. Ensenada: CICESE, 352, 352-365.

Rodríguez-Martínez, R. E., Medina-Valmaseda, A. E., Blanchon, P., Monroy-Velázquez, L. V., Almazán-Becerril, A., Delgado-Pech, B., ... & García-Rivas, M. C. (2019). Faunal mortality associated with massive beaching and decomposition of pelagic Sargassum. *Marine pollution bulletin*, 146, 201-205.

Rodríguez-Martínez, R. E., Jordán-Dahlgren, E., & Hu, C. (2022). Spatio-temporal variability of pelagic Sargassum landings on the northern Mexican Caribbean. *Remote Sensing Applications: Society and Environment*, 27, 100767.

Rodríguez-Martínez, R. E., Torres-Conde, E. G., & Jordán-Dahlgren, E. (2023). Pelagic Sargassum cleanup cost in Mexico. *Ocean & Coastal Management*, 237, 106542.

Rouse, J.W., Haas, R.H., Schell, J.A. and Deering, D.W. (1973) Monitoring Vegetation Systems in the Great Plains with ERTS (Earth Resources Technology Satellite). Proceedings of 3rd Earth Resources Technology Satellite Symposium, Greenbelt, 10-14 December, SP-351, 309-317.

Rouse, J. H., Shaw, J. A., Lawrence, R. L., Lewicki, J. L., Dobeck, L. M., Repasky, K. S., & Spangler, L. H. (2010). Multi-spectral imaging of vegetation for detecting CO₂ leaking from underground. *Environmental Earth Sciences*, 60, 313-323.

Ruíz-Rentería, F., van Tussenbroek, B. I., & Jordán-Dahlgren, E. (1998). Puerto Morelos, Quintana Roo, Mexico. CARICOMP: Caribbean coral reef, seagrass, and mangrove sites. Special Report UNESCO, Paris, 57-66.

Rumelhart, D. E., Durbin, R., Golden, R., & Chauvin, Y. (2013). Backpropagation: The basic theory. In *Backpropagation* (pp. 1-34). Psychology Press.

Rutten, J., Arriaga, J., Montoya, L. D., Mariño-Tapia, I. J., Escalante-Mancera, E., Mendoza, E. T., ... & Appendini, C. M. (2021). Beaching and natural removal dynamics of pelagic sargassum in a fringing-reef lagoon. *Journal of Geophysical Research: Oceans*, 126(11), e2021JC017636.

SAFMC. (2002). Fishery management plan for pelagic sargassum habitat of the South Atlantic Region. South Atlantic Fishery Management Council, National Marine Fisheries Service, NOAA. 153 pp.

Sakthivel, K., Nallusamy, R., & Kavitha, C. (2015). Color image segmentation using SVM pixel classification image. *International Journal of Computer and Information Engineering*, 8(10), 1924-1930.

Sargeant, P.G., 2015. What you need to know about Sargassum invading the Caribbean. <https://www.linkedin.com/pulse/what-you-needknow-sargassum-invading-caribbean-sargeant-gsm>

Schell, J. M., Goodwin, D. S., & Siuda, A. N. (2015). Recent Sargassum inundation events in the Caribbean: Shipboard observations reveal dominance of a previously rare form. *Oceanography*, 28(3), 8-11.

Senin, P. (2008). Dynamic time warping algorithm review. *Information and Computer Science Department University of Hawaii at Manoa Honolulu, USA*, 855(1-23), 40.

Shahapure, K. R., & Nicholas, C. (2020, October). Cluster quality analysis using silhouette score. In *2020 IEEE 7th international conference on data science and advanced analytics (DSAA)* (pp. 747-748). IEEE.

Shaw, G. A., & Burke, H. K. (2003). Spectral imaging for remote sensing. *Lincoln laboratory journal*, 14(1), 3-28.

Shin, J., Lee, J. S., Jang, L. H., Lim, J., Khim, B. K., & Jo, Y. H. (2021). Sargassum detection using machine learning models: A case study with the first 6 months of GOCI-II imagery. *Remote Sensing*, 13(23), 4844.

Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325.

Smetacek, V., & Zingone, A. (2013). Green and golden seaweed tides on the rise. *Nature*, 504(7478), 84-88.

Stoner, A. W., & Greening, H. S. (1984). Geographic variation in the macrofaunal associates of pelagic Sargassum and some biogeographic implications. *Marine ecology progress series*. Oldendorf, 20(1), 185-192.

Sullivan, E. (2022). Understanding from machine learning models. *The British Journal for the Philosophy of Science*.

Taborda, R., & Silva, A. (2012). COSMOS: A lightweight coastal video monitoring system. *Computers & geosciences*, 49, 248-255.

Taleby, A., Boussetta, M., & Benslimane, M. (2020). Faults detection for photovoltaic field based on k-means, elbow, and average silhouette techniques through the segmentation of a thermal image. *International Journal of Photoenergy*, 2020, 1-7.

Uribe-Martínez, A., Berriel-Bueno, D., Chávez, V., Cuevas, E., Almeida, K. L., Fontes, J. V., ... & Silva, R. (2022). Multiscale distribution patterns of pelagic rafts of sargasso (*Sargassum* spp.) in the Mexican Caribbean (2014–2020). *Frontiers in Marine Science*, 9, 920339.

Valentini, N.; Balouin, Y. Assessment of a Smartphone-Based Camera System for Coastal Image Segmentation and *Sargassum* monitoring. *J. Mar. Sci. Eng.* 2020, 8, 23.

Van Tussenbroek, B. I., Arana, H. A. H., Rodríguez-Martínez, R. E., Espinoza-Avalos, J., Canizales-Flores, H. M., González-Godoy, C. E., ... & Collado-Vides, L. (2017). Severe impacts of brown tides caused by *Sargassum* spp. on near-shore Caribbean seagrass communities. *Marine pollution bulletin*, 122(1-2), 272-281.

Wang, M., & Hu, C. (2016). Mapping and quantifying *Sargassum* distribution and coverage in the Central West Atlantic using MODIS observations. *Remote sensing of environment*, 183, 350-367.

Wang, M., & Hu, C. (2017). Predicting *Sargassum* blooms in the Caribbean Sea from MODIS observations. *Geophysical Research Letters*, 44(7), 3265-3273.

Wang, M., & Hu, C. (2021). Satellite remote sensing of pelagic *Sargassum* macroalgae: The power of high resolution and deep learning. *Remote Sensing of Environment*, 264, 112631.

Ward, W. C., Weidie, A. E., & Back, W. (1985). Frontmatter-Geology and Hydrogeology of the Yucatan and Quaternary Geology of Northeastern Yucatan Peninsula.

Wells, R. J., & Rooker, J. R. (2004). Spatial and temporal patterns of habitat use by fishes associated with *Sargassum* mats in the northwestern Gulf of Mexico. *Bulletin of Marine Science*, 74(1), 81-99.

Witherington, B., Hiram, S., & Hardy, R. (2012). Young sea turtles of the pelagic *Sargassum*-dominated drift community: habitat use, population density, and threats. *Marine Ecology Progress Series*, 463, 1-22.

Woergoetter, F., & Porr, B. (2008). Reinforcement learning. *Scholarpedia*, 3(3), 1448.

Xiao, Y., Zhang, J., & Cui, T. (2017). High-precision extraction of nearshore green tides using satellite remote sensing data of the Yellow Sea, China. *International Journal of Remote Sensing*, 38(6), 1626-1641.

Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of sensors*, 2017(1), 1353691.

Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316.

Yengoh, G. T., Dent, D., Olsson, L., Tengberg, A. E., & Tucker III, C. J. (2015). Use of the Normalized Difference Vegetation Index (NDVI) to assess Land degradation at multiple scales: current status, future trends, and practical considerations. Springer.

Zivkovic, Z. (2004, August). Improved adaptive Gaussian mixture model for background subtraction. In *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.* (Vol. 2, pp. 28-31). IEEE.

Zivkovic, Z., & Van Der Heijden, F. (2006). Efficient adaptive density estimation per image pixel for the task of background subtraction. *Pattern recognition letters*, 27(7), 773-780.