

UNIVERSIDAD NACIONAL DE TUMBES
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERIA FORESTAL Y
MEDIO AMBIENTE



**Cambios de la cobertura forestal en el Taller de Enseñanza e
Investigación Forestal y Fauna Silvestre del Ecosistema Bosque
Seco**

TESIS

Para optar el Título profesional de Ingeniero Forestal y Medio
Ambiente

Autor

Br. Leonardo Franco Espinoza Ramírez

Tumbes, 2026

UNIVERSIDAD NACIONAL DE TUMBES
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERIA FORESTAL Y
MEDIO AMBIENTE



**Cambios de la cobertura forestal en el Taller de Enseñanza e
Investigación Forestal y Fauna Silvestre**

Tesis Aprobada en forma y estilo por:

Dr. Eber Leopoldo Herrera Palacios. (presidente)

Mg. Eder Hidalgo Sandoval (secretario)

Dr. Miguel Antonio Puesca Chully. (Vocal)

Mg. Cesar Joel Feijoo Carrillo. (Accesitario)

Tumbes, 2026

UNIVERSIDAD NACIONAL DE TUMBES
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERIA FORESTAL Y
MEDIO AMBIENTE



**Cambios de la cobertura forestal en el Taller de Enseñanza e
Investigación Forestal y Fauna Silvestre**

**Los suscritos declaramos que la tesis es original en su contenido
y forma:**

Br. Leonardo Franco Espinoza Ramirez (Autor)

Dr. Miguel Antonio Puestas Chully (Asesor)

Mg. Antoni David Jimenez Dios (Coasesor)

Tumbes, 2026



**UNIVERSIDAD NACIONAL DE TUMBES
FACULTAD DE CIENCIAS AGRARIAS
EX FUNDO FISCAL LA CRUZ-CAMPUS UNIVERSITARIO
SECRETARIA ACADÉMICA**



"Año de la Esperanza y el Fortalecimiento de la Democracia"

ACTA DE SUSTENTACIÓN DE TESIS PRESENCIAL

En Tumbes, a los doce días del mes de marzo de dos mil veintiséis, siendo las 1.1 horas, con 2.0 minutos (veinte), de la mañana, de forma presencial, se reunieron en ambientes del pabellón "F" en la ciudad Universitaria., el Jurado Calificador, designado por Resolución N° 0056-2024/UNTUMBES-VRACAD-FCA-D, **Dr. Eber Leopoldo Herrera Palacios** (Presidente), **Mg. Eder Hidalgo Sandoval** (Secretario), **Dr. Miguel Antonio Puescas Chully** (Vocal) reconociendo en la misma resolución además, al **Dr. Miguel Antonio Puescas Chully**, como **Asesor** y al **Ing. Jiménez Dios Antoni David**, como **Co-asesor** se procedió a evaluar, calificar y deliberar la sustentación de la tesis, "**Cambios de la cobertura forestal en el Taller de Enseñanza e Investigación Forestal y Fauna Silvestre del Ecosistema Bosque Seco**", para optar el Título Profesional de Ingeniero Forestal y Medio Ambiente presentado por el **Bach. Leonardo Franco Espinoza Ramirez**, Concluida la sustentación y absueltas las preguntas, por parte del sustentante y después de la deliberación, el jurado según el artículo N° 75 del Reglamento de Tesis para Pregrado y Posgrado de la Universidad Nacional de Tumbes, declara al: **Bach. LEONARDO FRANCO ESPINOZA RAMIREZ**, aprobado, por unanimidad, con el calificativo Bueno,

Se hace conocer al sustentante, que deberá levantar las observaciones finales hechas al informe final de tesis, que el jurado le indica.

En consecuencia, queda apto para continuar con los trámites correspondientes a la obtención del Título Profesional de Ingeniero Forestal y Medio Ambiente, de conformidad con lo estipulado en la Ley Universitaria N° 30220, el Estatuto, Reglamento General, Reglamento General de Grados y Títulos y Reglamento de Tesis de la Universidad Nacional de Tumbes.

Siendo las 12 horas y 10 minutos del mismo día, se dio por concluida la ceremonia académica, procediendo a firmar el acta en presencia del público asistente.

Tumbes, 12 de marzo de 2026

Dr. Eber Leopoldo Herrera Palacios DNI N° <u>42450218</u> CODIGO ORCID <u>0000-0002-7255-9087</u> Presidente	Mg. Eder Hidalgo Sandoval DNI N° <u>42311217</u> CODIGO ORCID <u>0000-0002-8568-3255</u> Secretario
Dr. Miguel Antonio Puescas Chully DNI N° <u>02660522</u> CODIGO ORCID	

C.C. - JURADOS (03) -ASESOR Y(CO)-INTERESADO-ARCHIVO (Decanato)
S. Acad.

Informe de Similitud

Cambios de la cobertura forestal en el Taller de Enseñanza e Investigación Forestal y Fauna Silvestre

por Leonardo Franco Espinoza Ramírez



Dr. Miguel Antonio Puescas Chully
ORCID ID: 0000-0003-1979-9572
Asesor

Fecha de entrega: 18-ene-2025 11:13a.m. (UTC-0500)

Identificador de la entrega: 2566540732

Nombre del archivo: Informe_Final_Tesis-Leonardo_Espinoza-2025.pdf (5.81M)

Total de palabras: 14988

Total de caracteres: 78684

Cambios de la cobertura forestal en el Taller de Enseñanza e Investigación Forestal y Fauna Silvestre

INFORME DE ORIGINALIDAD

16%	15%	6%	7%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Nacional de Tumbes	2%
	Trabajo del estudiante	
2	hdl.handle.net	2%
	Fuente de Internet	
3	repositorio.untumbes.edu.pe	2%
	Fuente de Internet	
4	Roque Quiroz, Ruben Anthony. "Tendencia del NDVI en el Área de Conservación Regional Angostura Faical de Tumbes, Perú, 1999-2019", Manglar, 2022	1%
	Fuente de Internet	
5	idoc.pub	1%
	Fuente de Internet	
6	sigrid.cenepred.gob.pe	<1%
	Fuente de Internet	
7	doaj.org	<1%
	Fuente de Internet	

Dr. Miguel Antonio Puestas Chuly
Asesor de Tesis
ORCID ID: 0000-0003-1979-9572

8	repositorio.imta.mx Fuente de Internet	<1 %
9	www.aet.org.es Fuente de Internet	<1 %
10	Sánchez Borjas, Ángel Enrique. "Paisajes sagrados en el valle medio del río Chillón.", Pontificia Universidad Católica del Perú (Peru) Publicación	<1 %
11	repositorio.ucv.edu.pe Fuente de Internet	<1 %
12	repositorio.unal.edu.co Fuente de Internet	<1 %
13	www.cenicana.org Fuente de Internet	<1 %
14	ridum.umanizales.edu.co Fuente de Internet	<1 %
15	Submitted to Dept Uniagraria Fundación Universitaria Agraria de Colombia Trabajo del estudiante	<1 %
16	repository.usta.edu.co Fuente de Internet	<1 %
17	Submitted to Universidad Nacional Agraria La Molina Trabajo del estudiante	<1 %
	zaguan.unizar.es	



Dr. Miguel Antonio Puentes Chulfy
Asesor de Tesis
ORCID ID: 0000-0003-1979-9572

18	Fuente de Internet	<1 %
19	digibuo.uniovi.es Fuente de Internet	<1 %
20	riunet.upv.es Fuente de Internet	<1 %
21	www.clubensayos.com Fuente de Internet	<1 %
22	www.unipaz.edu.co Fuente de Internet	<1 %
23	ri.agro.uba.ar Fuente de Internet	<1 %
24	www.researchgate.net Fuente de Internet	<1 %
25	riuma.uma.es Fuente de Internet	<1 %
26	www.scilit.net Fuente de Internet	<1 %
27	erp.untumbes.edu.pe Fuente de Internet	<1 %
28	repositorio.unas.edu.pe Fuente de Internet	<1 %
29	Submitted to Universidad Catolica Los Angeles de Chimbote	<1 %



Dr. Miguel Antonio Puestas Chully
Asesor de Tesis
ORCID ID: 0000-0003-1979-9572

30 Submitted to Universidad Nacional Abierta y a Distancia, UNAD, UNAD <1 %
Trabajo del estudiante

31 www.risti.xyz <1 %
Fuente de Internet

32 ojs.upv.es <1 %
Fuente de Internet

33 repositorio.lamolina.edu.pe <1 %
Fuente de Internet

34 www.noriegacedec.com <1 %
Fuente de Internet

35 revistas.uaa.mx <1 %
Fuente de Internet

36 revistatyca.org.mx <1 %
Fuente de Internet

37 www.repositorio.usac.edu.gt <1 %
Fuente de Internet

38 Prasad S. Thenkabail. "Land Resources Monitoring, Modeling, and Mapping with Remote Sensing", CRC Press, 2015 <1 %
Publicación

39 repositorio.unap.edu.pe <1 %
Fuente de Internet

www.slideshare.net

Dr. Miguel Antonio Puestas Chuluy
Asesor de Tesis
ORCID ID: 0000-0003-1979-9572

40	Fuente de Internet	<1 %
41	"Aplicaciones del sensor MODIS para el monitoreo del territorio", Universidad Nacional Autónoma de México, 2011 Publicación	<1 %
42	apps.worldagroforestry.org Fuente de Internet	<1 %
43	livrosdeamor.com.br Fuente de Internet	<1 %
44	repositoriodigital.uns.edu.ar Fuente de Internet	<1 %

Excluir citas Activo

Excluir coincidencias < 15 words

Excluir bibliografía Activo



Dr. Miguel Antonio Puentes Chully

ORCID ID: 0000-0003-1979-9572

Asesor

DEDICATORIA

A Dios, por guiarme siempre en cada paso que doy, por darme salud y la fuerza necesaria para afrontar las situaciones difíciles.

A mis padres, por su amor, apoyo incondicional y esfuerzos, que han sido el pilar fundamental para alcanzar mis objetivos, ser perseverante y actuar siempre con valores.

A nuestros docentes de la escuela profesional de Ingeniería Forestal y Medio Ambiente, quienes diariamente tienen el compromiso y arduo trabajo de enseñarnos. Por haber compartido sus experiencias y sabios consejos esenciales para mi crecimiento personal y profesional.

AGRADECIMIENTO

En primer lugar, le agradezco a Dios por su amor, por cuidarme, y por haberme permitido llegar hasta aquí.

A mis padres, por su apoyo incondicional y motivarme siempre a salir adelante y a ser mejor persona.

Un agradecimiento especial a mi Asesor Dr. Miguel Antonio Puestas Chully y Co-Asesor Mg. Antoni Jiménez Dios, quienes me han ayudado durante la ejecución de esta investigación, sus experiencias y conocimientos han sido factores importantes para alcanzar este propósito.

ÍNDICE

ABSTRACT.....	xx
I. INTRODUCCIÓN.....	22
II. REVISION DE LITERATURA.....	24
2.1. Bases teóricas – científicas.....	24
2.1.1. Teledetección y fotogrametría.....	24
2.1.2. Aeronave pilotada a distancia (RPA).....	25
2.1.3. Índices de vegetación.....	25
2.1.4. Fracción de cobertura del vegetal.....	25
2.2. Antecedentes:	26
III. MATERIALES Y MÉTODOS	34
3.1. Tipo de investigación	34
3.2. Área de estudio.....	34
3.3. Población y muestra.....	35
3.4. Unidades de muestreo	35
3.5. Equipos y materiales	35
3.5.1. Software	35
3.5.2. Equipos.....	35
3.6. Metodología	36
3.6.1. Parámetros de vuelo.....	36
3.6.2. Procesamiento de fotografías aéreas.....	37
3.6.3. Segmentación mediante OBIA (clasificación basada en objetos).....	37
3.6.4. Datos de entrenamiento y validación	38
3.6.5. Clasificación de Random Forest (RF).....	39
3.6.6. Evaluación de la precisión del clasificador.....	39
3.6.7. Índices de vegetación.....	40
3.6.8. Mapeo de la cobertura leñosa fraccionada	41
3.6.9. Relación entre FCC y los índices de vegetación	41
3.6.10. Análisis multitemporal de los cambios en la cobertura fraccional	42
IV. RESULTADOS Y DISCUSIONES	44
4.1. Clasificación de la cobertura vegetal del área de estudio, aplicando el clasificador de Random Forest.....	44
4.2. Correlación de índices de vegetación y cobertura fraccionaria (FCC)	48
4.3. Análisis multitemporal mediante imágenes satelitales Landsat.....	53

V. CONCLUSIONES	64
VI. RECOMENDACIONES	65
VII. REFERENCIAS BIBLIOGRAFICAS	66
VIII. ANEXOS	72

ÍNDICE TABLAS

Tabla 1. Especificaciones técnicas del equipo RPA Phantom 4 multiespectral	36
Tabla 2. Parámetros de vuelo del equipo RPA	36
Tabla 3. Índices espectrales de vegetación.....	40
Tabla 4. Datos de la estación meteorológica de Puerto Pizarro	43
Tabla 5. Métricas de precisión en índices convencionales y diferenciales	49
Tabla 6. Métricas de precisión en índices ajustados por reflectancia del suelo	49
Tabla 7. Métricas de precisión en índices convencionales corregidos y modificados ...	49
Tabla 8. Modelos de regresión cubica entre FC y NDVI, OSAVI	50
Tabla 9. Modelos de regresión lineal múltiple para predecir FC.....	52
Tabla 10. Valor de fracción de la cobertura vegetal (FCV).....	53
Tabla 11. Cambios de la fracción de cobertura vegetal periodo 1986 - 1999.....	56
Tabla 12. Cambios de la fracción de cobertura vegetal periodo 1999 - 2014.....	56
Tabla 13. cambios de la fracción de cobertura vegetal periodo 2014 - 2024	57
Tabla 14. Cambios de la fracción de cobertura vegetal periodo de 1986 - 2024	58

ÍNDICE FIGURAS

- Figura 1. Radiación electromagnética del planeta tierra **¡Error! Marcador no definido.**
- Figura 2. Mapa de ubicación de la concesión forestal de la Universidad Nacional de Tumbes **34**
- Figura 3. Proceso metodológico del procesamiento de fotografías aéreas **¡Error! Marcador no definido.**
- Figura 4. Segmentación de ortofoto mediante SNIC **¡Error! Marcador no definido.**
- Figura 5. Distribución de puntos de muestreo para el entrenamiento y validación **¡Error! Marcador no definido.**
- Figura 6. Clasificación de coberturas mediante Radom Forest **¡Error! Marcador no definido.**
- Figura 7. Precisión en la clasificación supervisada con diferentes datos SEEDGRID **¡Error! Marcador no definido.**
- Figura 8. Clasificación supervisada Randon Forest y ortomosaico RGB en parcela 1, 2 y 3 **¡Error! Marcador no definido.**
- Figura 9. clasificación supervisada Randon Forest y ortomosaico RGB en parcela 4 y 5 **¡Error! Marcador no definido.**
- Figura 10. Coeficiente de pearson de la regresión lineal de todas las variables **¡Error! Marcador no definido.**
- Figura 11. Regresión cubica entre FC y NDVI **¡Error! Marcador no definido.**
- Figura 12. Regresión cubica entre FC y OSAVI **¡Error! Marcador no definido.**
- Figura 13. Fracción de la cobertura vegetal en el área de estudio **¡Error! Marcador no definido.**
- Figura 14. Serie de tiempo entre precipitación (mm/año) y NDVI durante el periodo de 1986 - 1999 **¡Error! Marcador no definido.**
- Figura 15. Precipitación histórica de la estación meteorológica de Puerto Pizarro **¡Error! Marcador no definido.**
- Figura 16. Serie de tiempo entre precipitación (mm/año) y NDVI durante el periodo de 1999 - 2014 **¡Error! Marcador no definido.**
- Figura 17. Serie de tiempo entre precipitaciones (mm/año) y NDVI durante el periodo 2014 - 2024 **¡Error! Marcador no definido.**
- Figura 18. Serie de tiempo entre precipitaciones (mm/año) y NDVI durante el periodo 1986 - 2024 **¡Error! Marcador no definido.**

ÍNDICE ANEXOS

Anexo 1. Parámetros de procesamiento de la parcela 1	72
Anexo 2. Parámetros de procesamiento de la parcela 2	74
Anexo 3. Parámetros de procesamiento de la parcela 3	76
Anexo 4. Parámetros de procesamiento de la parcela 4	78
Anexo 5. Parámetros de procesamiento de la parcela 5	80
Anexo 6. fotografía panorámica del área de estudio	82
Anexo 7. Mapa de la fracción de cobertura vegetal del año 1986 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes.....	83
Anexo 8. Mapa de la fracción de cobertura vegetal del año 1999 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes.....	84
Anexo 9. Mapa de la fracción de cobertura vegetal del año 2014 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes.....	85
Anexo 10. Mapa de la fracción de cobertura vegetal del año 2024 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes.....	86
Anexo 11. Precipitaciones pluviales histórica de la Estación Meteorológica "Puerto Pizarro"	87

RESUMEN

La presente investigación tuvo como objetivo evaluar los cambios en la cobertura forestal en el taller de enseñanza de investigación forestal y fauna silvestre utilizando vehículos aéreos no tripulados y sensores remotos. La metodología consiste en determinar la cobertura leñosa mediante RGB de las ortofotos generadas en el software Agisoft Metashape, con un tamaño de píxel de 4 cm, utilizamos la clasificación supervisada mediante el algoritmo de Random Forest en la plataforma de Google Earth Engine, obteniendo las siguientes clases (I) vegetación fotosintéticamente activa, (II) vegetación no fotosintética y (III) suelo desnudo, posteriormente se obtuvo la fracción de la cobertura vegetal, mediante cuadrantes de 50 m x 50 m, superponiendo las capas de vegetación leñosa (vegetación fotosintéticamente activa + vegetación no fotosintética), relacionándolo con 09 índices de vegetación obtenidas de las imágenes satelitales Landsat 5, 7, 8 y 9, los modelos predichos se obtienen mediante las regresión lineal, cuadrática, cúbica, exponencial y múltiple.

Finalmente se selecciona la ecuación con mayor precisión para estimar la fracción de cobertura vegetal en los periodos de 1986, 1999, 2014 y 2024, relacionando con las precipitaciones pluviales obtenidas de la estación meteorológica de Puerto Pizarro. Los resultados muestran que el algoritmo de Random Forest tiene una alta capacidad de clasificación de la cobertura terrestre en imágenes de vehículo aéreo no tripulado, obteniendo una exactitud de 0.88 y coeficiente de kappa de 0.82, cuando el valor de seedgrid es de 3, durante la segmentación.

La estimación de la fracción de cobertura vegetal, señala que la regresión cúbica presenta mejores resultados en los índices de NDVI y OSAVI, con valores de R^2 de 0.64 y 0.645, con errores en la estimación de RMSE y MAE de 6.60%, 6.50% y 5.50% y 5.40%, sin embargo, la regresión múltiple presenta una mejor precisión, donde el modelo 1, presenta un coeficiente de determinación R^2 de 0.6848 y errores RMSE y MAE de 6.17% y 5.19%. Finalmente, en el análisis histórico de los cambios de la cobertura vegetal se obtiene un incremento en la

fracción de la cobertura vegetal en 125.674 ha, dichos resultados son influenciados por la variabilidad climática, originando estimaciones erróneas, en épocas de lluvias intensas por el fenómeno El Niño, generando un efecto acumulativo en años posteriores. La presente investigación genera una metodología científica que ayuda a determinar el grado de deforestación y degradación como la recuperación en un ecosistema bosque seco.

Palabras claves: Fracción de la cobertura vegetal, Randon Forest, Vehiculos Aereos No Tripulados, Google Earth Engine

ABSTRACT

The present research aimed to evaluate changes in forest cover in the forestry and wildlife research teaching workshop using unmanned aerial vehicles and remote sensors. The methodology consists in determining the woody cover by RGB of the orthophotos generated in the Agisoft Metashape software, with a pixel size of 4 cm, we use the supervised classification using the Random Forest algorithm on the Google Earth Engine platform, obtaining the following classes (I) photosynthetically active vegetation, (II) non-photosynthetic vegetation and (III) bare soil, subsequently the fraction of the vegetation cover was obtained, using quadrants of 50 m x 50 m, superimposing the layers of woody vegetation (photosynthetically active vegetation + non-photosynthetic vegetation), relating it to 09 vegetation indices obtained from Landsat 5, 7, 8 and 9 satellite images, the predicted models are obtained through linear, quadratic, cubic, exponential and multiple regression. Finally, the equation with the highest accuracy is selected to estimate the fraction of vegetation cover in the periods of 1986, 1999, 2014 and 2024, relating it to the rainfall obtained from the Puerto Pizarro meteorological station. The results show that the Random Forest algorithm has a high capacity to classify land cover in UAV images, obtaining an accuracy of 0.88 and a kappa coefficient of 0.82, when the seedgrid value is 3, during segmentation. The estimation of the fraction of vegetation cover indicates that the cubic regression presents better results in the NDVI and OSAVI indices, with R² values of 0.64 and 0.645, with errors in the estimation of RMSE and MAE of 6.60%, 6.50% and 5.50 % and 5.40 %, however the multiple regression presents a better precision, where model 1 presents a coefficient of determination R² of 0.6848 and RMSE and MAE errors of 6.17 % and 5.19 %. Finally, in the historical analysis of changes in vegetation cover, an increase in the fraction of vegetation cover of 125,674 ha is obtained. These results are influenced by climate variability, giving rise to erroneous estimates in periods of intense rainfall due to the El Niño phenomenon, generating a cumulative effect in subsequent years. This research

generates a scientific methodology that helps determine the degree of deforestation and degradation as well as the recovery in a dry forest ecosystem.

Keywords: Vegetation Cover Fraction, Random Forest, Unmanned Aerial Vehicles, Google Earth Engine

I. INTRODUCCIÓN

El Perú cuenta con más de 72 millones de hectáreas de bosques de alta biodiversidad, segundo país con mayor extensión forestal en América Latina, cuarto con mayor superficie de bosques tropicales, y se encuentra entre los 10 países del planeta con mayor extensión de masas arboladas (FAO, 2016). Dentro de estas masas se caracteriza el bosque seco, donde se estima que abarca una área de 3.6 millones de hectáreas, lo que representa el 4.7 % del total de los bosques en el Perú (MINAM, 2021), estos bosques tienen la característica de cubrirse de follaje en época de lluvias y perderla al llegar la época seca (Angulo, 2009), son ecosistemas únicos y frágiles, considerado una de las zonas ecológicas de mayor importancia debidos a su complejo comportamiento, dinámicas ambientales y servicios ecosistémicos (Aguirre Padilla, Alvarado Espejo, & Granda Pardo, 2018), sin embargo estos bosques viene siendo amenazados por diversas actividades antrópicas ocasionando la deforestación a través de la tala selectiva, agricultura y ganadería caprina y bovina (Angulo, 2009), estas amenazas generan la degradación forestal y afecta la estructura, composición y diversidad de especies, funcionalidad y procesos ecosistémicos. Existe dificultades para utilizar la teledetección para cuantificar la degradación forestal, en un área que permanece como bosque, pero su estructura y composición fueron alteradas (Gao, Skutsch, Paneque-Gálvez, & Ghilardi, 2020), es por ello que se busca alternativas para lograr determinar con mayor precisión la degradación forestal, a través de la fracción del dosel forestal, la cual permite medir la degradación por tala selectiva (Wang, Qi, & Cochrane, 2005).

La necesidad de buscar una metodología que permita cuantificar los cambios de la cobertura forestal, entre degradación, deforestación y recuperación del bosque, la presente investigación, se desarrolla mediante el uso de fotografías

aéreas, obtenidas mediante vehículo aéreo no tripulado (RPA), para determinar la fracción de la cobertura vegetal, relacionándolo con índices de vegetación obtenidas del sensor Landsat 5 TM, Landsat 7 ETM+, Landsat 8 OLI y Landsat 9 OLI. Los resultados obtenidos fueron analizados con las precipitaciones históricas de la estación meteorológica “Puerto Pizarro”, explicando la variabilidad de los resultados acorde a las lluvias.

La presente investigación tiene como objetivo “Evaluar los cambios de la cobertura forestal en el Taller de Enseñanza e Investigación Forestal y Fauna Silvestre del Ecosistema Bosque Seco”, del cual genera información importante que permite determinar la degradación del bosque en relación a la fracción de cobertura vegetal.


II. REVISION DE LITERATURA

2.1. Bases teóricas – científicas

2.1.1. Teledetección y fotogrametría

Es la obtención de información sobre un objeto desde una distancia. La energía que la tierra recibe del sol, se denomina radiación electromagnética y es reflejada, absorbida y emitida por la superficie terrestre. Los satélites llevan instrumentos o sensores que miden la radiación reflejada o emitida tanto por fuentes terrestres o atmosféricas; con instrumentos calibrados es posible medir la altura, temperatura, contenido de humedad, etc. Para casi todos los atributos de la litosfera y biosfera terrestre. (NASA ARSET, 2024).

Figura 1. Radiación electromagnética del planeta tierra



Fuente: NASA ARSET, 2024

La fotogrametría, es la ciencia por el cual las fotografías del terreno, se consigue deducir su planta y alzado, logrando formar un plano topográfico del mismo. Las fotografías pueden tomarse desde tierra o aire. Se define como el conjunto de métodos y procedimientos donde deducimos de la fotografía un objetivo, forma y dimensiones. (Santamaria & Sanz, 2011). La fotogrametría con drones permite adquirir información del relieve de la superficie del terreno,

donde es posible elaborar mapas de alta resolución, mediciones de longitudes, volumen, área y modelar superficies en 3D con alta precisión. (IGP, 2020)

2.1.2. Aeronave pilotada a distancia (RPA)

Un RPA, es una aeronave pilotada remotamente, emplazado en una estación remota fuera de la aeronave (tierra, barco, otras aeronaves, etc.), quien monitorea la aeronave y tiene responsabilidad de la conducción segura durante el vuelo. (Ministerio de Transporte y comunicaciones, 2015). Un dron o Vehículo Aéreo no Tripulado (VAN), es una aeronave con la habilidad de volar sin piloto, es controlada por ondas de radio mediante un control remoto localizado en tierra. Está equipado con accesorios como baterías, cámara, protectores, hélices, etc., lo que permite obtener fotografías del área de estudio. (IGP, 2020)

2.1.3. Índices de vegetación

El índice de vegetación (IV), es un parámetro calculado a partir de los valores de reflectividad a distintas longitudes de onda y que pretende extraer información relacionada con la vegetación minimizando la influencia de factores externos como las propiedades ópticas del suelo, irradiación solar, entre otras. El índice de vegetación ideal se describe como aquel particularmente sensible a la cubierta vegetal, insensible al brillo y color del suelo y poco afectado por las perturbaciones atmosféricas, factores medioambientales y la geometría de iluminación y de observación, por lo general, no existe el índice de vegetación ideal, lo que se encuentra en la bibliografía son distintas aproximaciones. (Sobrino, 2001)

2.1.4. Fracción de cobertura del vegetal

La cobertura del dosel forestal, es un parámetro ecológico importante de los ecosistemas forestales y se relaciona con las características del bosque, incluido el crecimiento de las plantas, regeneración, biodiversidad, regímenes de luz y propiedades hidrológicas. (Nasiri, y otros, 2022). Es un parámetro importante en el estudio del equilibrio de los ecosistemas, la erosión y el cambio climático, y se utiliza a menudo para evaluar y monitorear la degradación de la vegetación y desertificación (Chu, 2019)

2.2. Antecedentes:

(Barati, Rayegani, Saati, Sharifi, & Nasri, 2011); Mencionan que las variables biofísicas del dosel son muy importantes en diferentes estudios como la meteorología, la agricultura y ecología, por lo que el conocimiento de la distribución espacial y temporal de estas variables sería muy beneficioso. Pero a menudo los reflejos del suelo y las rocas son muchos más que los reflejos de la vegetación rala en estas áreas, lo que dificulta la separación de las señales de las plantas. Por ende en este estudio evaluaron la cobertura vegetal fraccional medida en una área desértica utilizando 20 índices de vegetación en cinco categorías diferentes, incluyen (1) índices de relación y diferenciales como el NDVI (índice de diferencia normalizada); (2) índices corregidos y derivados de los indicadores tradicionales como el NDVIc (índice de diferencia normalizada corregido) y GNDVI (índice de diferencia normalizada verde); (3) índices ajustados por reflectancia del suelo como el SAVI (Índice de vegetación ajustado al suelo); (4) índices triangulares basados en tres bandas discretas en su ecuación (verde, rojo y nir) como el TVI (índice de vegetación transformado); y (5) índices no convencionales y diferenciales como el CI (índice de clorofila). Según los resultados, el índice DVI mostro un coeficiente de determinación R^2 de 0.668, con la mejor estimación de la cobertura vegetal fraccional. La escasa vegetación en las áreas desérticas y los resultados obtenidos en la investigación, hace entender que ninguno de los índices por sí solo pueden estimar con precisión el porcentaje de cobertura fraccional; sin embargo, los resultados mejorar mediante modelos de regresión multivariante. El uso de este método nos permitió aumentar el coeficiente del modelo con una cobertura fracciona hasta de 0.797.

(Bolaf-Mena, Tanase, & Gómez-Sal, 2019), Este estudio se centra en evaluar y comparar métodos para la estimación de la cubierta arbórea a partir de ortofotos de alta resolución y escaneo láser aéreo (ALS). El procesamiento de imágenes RGB basado en el umbral del índice 'Exceso verde menos exceso rojo' con el método Otsu produjo resultados aceptables (80%), inferiores a los obtenidos al umbralizar el modelo digital de dosel obtenido a partir de los datos ALS (87%) o al combinar datos RGB y LiDAR (87,5%). Se encontró que la

información RGB era útil para la delineación de los árboles, aunque muy vulnerable a la confusión con la hierba o los arbustos.

(Cai, y otros, 2022), Este estudio evaluó el incremento y la tasa de cambio de la cobertura vegetal fraccionada (CVF) en 2000-2020 en China. Las influencias de los tipos de tierra y los principales proyectos ecológicos se compararon sistemáticamente para evaluar el nexo vegetación-humano. China ha experimentado un reverdecimiento progresivo en el período de estudio con variaciones regionales en los patrones y las causas. Los cambios de la CVF y las variaciones espaciotemporales fueron inducidos por actividades humanas notables como la conversión del uso de la tierra, los programas de forestación de China (CAP), el Proyecto Bosque de Hormigas (AFP) y el Programa de Conversión de Tierras de Cultivo a Bosques (CCFP). La región Norte registró la tasa de cambio más alta. Los cambios en la superficie de las tierras de cultivo, los pastizales y los bosques fueron los principales impulsores de la CVF. La tasa media de cambio de la CVF de la CAP ha experimentado cambios muy altos en 21 años. El AFP ha tenido un impacto significativo en los cambios de la CVF.

(Campaña-Olaya & Gines Tafur, 2021); La presente investigación, se realizó para determinar el grado de deforestación y sequía en la Reserva Nacional de Tumbes, donde emplearon imágenes de diferentes años 1986 hasta 2019, del sensor Landsat. La sequía se determinó utilizando el índice de agua diferencial normalizado (NDWI) y para determinar la vegetación forestal se utilizó el índice de vegetación de diferencia normalizada (NDVI), la sequía con el NDWI, la mayor sequía tuvo valores entre 0.2 – 0.4 y > 0.4 clasificándose en área con poca sequía y bajo contenido de humedad. La vegetación alta, fue mayor en 1986 alcanzando 19 142.28 ha y los valores más bajos se registraron en el 2005 y 2010, donde el área fue de 15 401.25 ha y 15 094.53 ha, en el año 2019 el área fue de 18 219.51 ha, la cual se ha recuperado en los últimos 10 años.

(Campos-Vargas, Sanchez-Azofeifa, Laakso, & Marzahn, 2020), la presente investigación evalúan la precisión y los tiempos de procesamiento de diez técnicas de aprendizaje automático (ML), aplicadas a datos multiespectrales de vehículos aéreos no tripulados (UAV) para detectar componentes leñosos

mueritos del dosel; el trabajo fue realizado en cico parcelas de bosque seco secundario ubicado en el Parque Nacional Santa Rosa, Costa Rica, los resultados estiman la cobertura e componentes leosos mueritos en las parcelas de bosque seco secundario seleccionadas, oscilaban entre 4.8 % y 16.1 %, sin diferencias en las etapas sucesionales. De las diez técnicas de ML, la máquina de vectores de soporte con núcleo radial (SVMR) y los bosques aleatorios (RF), proporcionan las precisiones más altas. En conclusión, a los resultados, es posible detectar y cuantificar componentes leñosos mueritos, como masas mueritas y árboles caídos, utilizando una combinación de datos UAV de alta resolución y algoritmos ML.

(Chu, 2019); En el presente estudio, se desarrolla un modelo empírico de estimación de la CVF para la meseta tibetana central (TP) basado en las relaciones entre los índices de vegetación del espectrorradiómetro de imágenes de resolución moderada Terra/MODIS (Terra/Moderate Resolution Imaging Spectroradiometer) y las mediciones de campo correspondientes derivadas de la cámara digital, que es seguido por un análisis en profundidad de la distribución espacial de la cobertura vegetal utilizando el método propuesto. El estudio muestra que existe una relación lineal entre la cobertura vegetal de la observación de campo y el NDVI de MODIS con un coeficiente de determinación de $R^2 = 0,90$, que es ligeramente mejor que el rendimiento de MODIS SAVI con $R^2 = 0,89$ y es un modelo de regresión óptimo para la estimación de la CVF.

(Escate Buitrón, y otros, 2024), analizaron la relación entre vigorosidad de las coberturas vegetales, fluctuaciones históricas en la densidad poblacional del venado de cola blanca (*Odocoileus virginianus peruvianus*), con las variaciones climáticas e incidencia del el Niño Costero en el Coto de Caza El Angolo y su zona de amortiguamiento en el periodo de 1984 – 2023. Se correlaciono la data estadística del venado cola blanca y los niveles de vigorosidad de vegetación mediante el NDVI, mediante imágenes Landsat y data meteorológicas. Resultados indican la vigorosidad de la vegetación tiene una fuerte fluctuación hasta 2002, donde presenta un comportamiento más regulado , pero en franco asenso, fenómeno que coincide con el incremento en la recurrencia de los eventos El Niño, lo que habría generado un incremento de la cobertura foliar

densa y escasa al 2005, cambio que afectarían a las poblaciones de venado cola blanca.

(Godingo, Guiomar, & Gil, 2018); En su estudio exploraron las capacidades multiespectrales de Sentinel 2 A, en combinación con una técnica de modelado estocástico, para mapear el porcentaje de cobertura arbórea (CCP) a nivel de pixel. Los resultados del estudio mostraron que la combinación de bandas multiespectrales con los índices de vegetación seleccionados y las características de textura de la matriz de coocurrencia de niveles de gris (GLCM) funciona bien, presentando un coeficiente de determinación (R^2) de 82,8% y una predicción de error de 8,68%. El análisis también mostró que el NDVI y el índice de reflectancia de senescencia de las plantas (PSRI), así como la característica de textura de homogeneidad fueron las variables predictoras más importantes para llevar a cabo la estimación compleja de la cobertura del dosel de los árboles.

(Matricardi, Skole, Pedlowski, Chomentowski, & Fernandes, 2010); Realizaron un análisis detallado de los impactos de la tala selectiva e incendios forestales en los bosques naturales de Mato Grosso, sur de la amazonia brasileña, utilizaron 13 años de imágenes anuales Landsat (1992 – 2004), probando diferentes técnicas de teledetección y medir la extensión de la tala y los incendios forestales. Nuestros resultados indicaron que el Índice de Vegetación Ajustado al Suelo Modificado libre de aerosoles ($MSAVI_{af}$) es un estimador confiable de la cobertura fraccional tanto en condiciones de cielo despejado como de humo en esta región de estudio. Durante el período de análisis, la tala selectiva fue responsable de perturbar la mayor proporción (31%) de bosque natural en el área de estudio, seguida inmediatamente por la deforestación (29%)

(Nasiri, y otros, 2022); Su investigación presenta un enfoque de combinación de datos Sentinel 2, imágenes aéreas de alta resolución y algoritmos de aprendizaje automático (ML) para modelar FCC en bosque templado mixto de Hyrcanian, norte de Irán. Las bandas multiespectrales de Sentinel 2 y los índices de vegetación se utilizaron como variables para modelar y mapear la cobertura del dosel forestal (FCC). El bosque aleatorio (RF), máquina de vectores de soporte (SVM), red elástica (ENET) y el impulso de gradiente

externo (XGBoost) fueron los algoritmos de ML utilizados para aprender y generalizar sobre variables detectadas de forma remota. La evaluación de la importancia de las variables indicó que los índices de vegetación, incluidos NDVI, NDVI-A, NDRE y NDI45, fueron las predictoras dominantes en la mayoría de los modelos. Los resultados de la estimación de la precisión del modelo mostraron que, entre los modelos probados, RF ($R^2 = 0,67$, RMSE = 18,87 %, MAE = 15,35 %) y ENET ($R^2 = 0,63$, RMSE = 20,04 %, MAE = 16,44 %) mostraron el mejor y el peor rendimiento, respectivamente. En conclusión, fue posible demostrar la idoneidad de la integración de imágenes RGB obtenidas con UAV, datos de Sentinel-2 y modelos ML para la estimación de FCC, destinada a un mapeo preciso y rápido a escala de paisaje.

(Fern, Foxley, Bruno, & Morrison, 2018); El índice de vegetación de diferencia normalizada (NDVI), es el más utilizado, sin embargo, en regiones de vegetación seca o suelos que generan altos valores de reflectancia (suelos arenosos secos), pueden obstaculizar la confiabilidad del NDVI. El índice de vegetación ajustado al suelo optimizado (OSAVI), es una alternativa nueva que puede adaptarse a una mayor variabilidad debido a los altos valores de fondo del suelo. Evaluaron la idoneidad del NDVI y el OSAVI, como posibles estimadores de biomasa verde y cobertura vegetal en un pastizal semiárido de Texas. Las estimaciones de cobertura derivadas de OSAVI de la vegetación herbácea y leñosa no difirieron significativamente de las producidas por los estudios de terreno en 2015. Sin embargo, las estimaciones basadas en NDVI para la vegetación leñosa, así como para el suelo desnudo, sí difirieron significativamente de las estimaciones generadas a partir de los estudios de terreno ($p = 0,012, 0,018$). En 2016, las estimaciones derivadas de OSAVI para las tres clases de cobertura terrestre no fueron significativamente diferentes de las producidas por estudios terrestres. Los resultados indican que el OSAVI es el estimador más apropiado de biomasa verde y cobertura vegetal en regiones semiáridas.

(Roque Quiroz, 2022); En el Área de Conservación Regional Angostura Faical, se determinó la tendencia del NDVI, utilizando imágenes satelitales Landsat 5-7-8 en la plataforma de Google Earth Engine, además se empleó el lenguaje Rstudio para el análisis estadístico con el test de Mann Kendall. Se encontró 7

304,568 hectáreas de tendencia neutral, 1 489, 457 hectáreas con tendencia positiva y 0.458 ha con tendencia negativa.

(Scanlon, Albertson, Caylor, & Williams, 2002); presenta un método para estimar la cobertura fraccional en función de las diferentes formas en que los pastos y árboles responde a las precipitaciones, a lo largo del transecto Kalahari, en el sur de África. El NDVI y la sensibilidad del NDVI a las variaciones interanuales en las precipitaciones de la estación húmeda y se utilizan como variables de espacio de estados en un modelo de desmezcla lineal. Los miembros finales obtenidos fueron consistentes con las características cualitativas de los árboles (NDVI alto, baja sensibilidad del NDVI a las variaciones interanuales en las precipitaciones), el suelo desnudo (NDVI bajo, baja sensibilidad) y el área transitoria de pasto/suelo desnudo (NDVI moderado, alta sensibilidad). La sensibilidad observada del NDVI a la lluvia se midió como la relación entre el NDVI de la estación húmeda y la lluvia normalizada durante un período de 16 años (1983-1998).

(Vatandaşlar & Yavuz, 2017); El presente estudio, estimaron el factor de gestión de la cobertura (C), con la ecuación universal revisada de pérdida de suelo (RUSLE), en la subcuenca Tortum-North, en la parte montañosa del noroeste de Turquía, se estimó utilizando valores NDVI derivados de las imágenes WorldView-2 de 50 cm de resolución. Los valores del factor c, recopilados de 55 parcelas de muestreo midiendo el cierre de la copa, altura del dosel, profundidad de hojarasca y la cobertura de la superficie, donde se graficaron frente a los valores de NDVI y luego se correlacionaron utilizando modelos de regresiones (lineal, cúbico, exponencial, de crecimiento). Los resultados indican el modelo cúbico tuvo buen desempeño.

(Vigabriel Navarro, Osorio Leyton, Quezada Lambertin, & Benavides Lopez, 2024); utilizo el potencial de los vehículos aéreos no tripulados y análisis de imágenes multiespectrales, para estimar biomasa en la cebada del altiplano boliviano, cuya biomasa se estimó mediante el cálculo del índice de vegetación NDVI y ecuación de regresión polinomial. El modelo demuestra una fuerte correlación entre NDVI y biomasa con un valor de R^2 de 0.94. esta investigación permite el uso de la teledetección para mejorar la gestión agrícola.

(Wang, y otros, 2022), El presente estudio cartografió la vegetación natural del oasis Dariyabui en el desierto de Taklamakan en China, utilizando 2550 muestras de datos y 14 índices de vegetación visible y multiespectral. Aplicaron seis métodos de aprendizaje automático para construir modelos de regresión predictiva de cobertura vegetal fraccional (FCV). Se utilizaron el coeficiente de determinación (R^2), el error cuadrático medio (RMSE) y el error absoluto medio (MAE) para evaluar los modelos. Los modelos de regresión se dividieron en cuatro componentes: visible RF: $R^2 = 0,65$, RMSE = 0,59 %, MAE = 0,41 %), multiespectral (RF: $R^2 = 0,71$, RMSE = 0,54 %, MAE = 0,36 %), visible y multiespectral (RF: $R^2 = 0,69$, RMSE = 0,55 %, MAE = 0,37 %), y el producto de los índices de vegetación visible y multiespectral (RF: $R^2 = 0,68$, RMSE = 0,57 %, MAE = 0,39 %). Los resultados indican que los cuatro modelos pueden obtener efectivamente la FVC.

(Xie, y otros, 2022); utilizaron imágenes RGB de dos periodos: imágenes del 2006, capturadas con una aeronave tripulada pequeña y ligera y con una resolución de 0.1 m, e imágenes de 2019 capturadas con un vehículo aéreo no tripulado (UAV) con una resolución de 0.02 m. aplicaron tres algoritmos de aprendizaje automático basado en píxeles, árbol de decisión de mejora gradiente (GBDT), k-vecino más cercano (KNN) y bosque aleatorio (RF), para clasificar vegetación leñosa y calcular la cobertura. Las precisiones generale de GBDT, KNN y RF, para la clasificación del 2006 fueron 0.9140, 0.9190, 0.9478, respectivamente, y RF logró p los mejores resultados de clasificación. Para el año 2019 fueron de 0.8466, 0.8627 y 0.8559, respectivamente y el algoritmo de KNN logró los mejores resultados para la clasificación. Los resultados muestran que las imágenes RGB son adecuadas para mapear la cobertura vegetal fraccionada.

(Xu, y otros, 2023), En el presente estudio se utilizó el índice de vegetación sombreada normalizada (NSVI), para comparar la capacidad de estimar la cobertura vegetal fraccionada (CVF) con el índice de vegetación de diferencia normalizada (NDVI). Con base en dos dimensiones de jerarquías “brillantes” y “sombras” y rangos de CVF. Se seleccionaron cuatro sistemas de evaluación de la relación señal-ruido (SNR), rango del índice, modelo estadístico y modelo de píxeles dimediatos a partir de Sentinel 2 A MSI, Landsat 8 OLI y Resource

– 1 . 02D(ZY1-02D) y cubrieron una variedad de paisajes topográficos. El NSVI y NDVI tienen sus propias ventajas en relación señal-ruido, rango de índice, modelo estadístico y modelos de píxeles dimedios, por lo que se sugiere que cuando se realiza una estimación CVF mediante teledetección, se debe preferir el NSVI en áreas de CVF de rango medio-alto y alto, y se debe preferir el NDVI en áreas de CVF de rango bajo en áreas sombreadas.

(Zheng, y otros, 2022); construyeron un conjunto de datos basados en vehículos aéreos no tripulados (UAV) y compararon el empeño de los métodos de PB (métodos basados en píxeles), OBIA (análisis basados en objetos) y DL (aprendizaje profundo), en la clasificación de comunidades de vegetación de humedales costeros, basado en Google Earth Engine. Los resultados muestran que el método DL logró mejores resultados en la clasificación. Sugieren que la combinación de UAV, DL y plataformas de computación en la nube puede facilitar el monitoreo preciso a largo plazo de la vegetación en humedales costeros a escala local.


III. MATERIALES Y MÉTODOS

3.1. Tipo de investigación

3.2. Área de estudio

El área de estudio corresponde al taller de enseñanza e Investigación Forestal y Fauna Silvestre , perteneciente a la Universidad Nacional de Tumbes, tiene una superficie de 127. 23 ha y 5 441.99 m de perímetro; se encuentra ubicada en el centro poblado de Garbanzal en las coordenadas UTM 563960 E y 9601120 N, distrito de San Juan de la Virgen, provincia y departamento de Tumbes; en la siguiente figura 2, se observa la ubicación política del área de estudio.

Figura 2. Mapa de ubicación de la concesión forestal de la Universidad Nacional de Tumbes



3.3. Población y muestra

La población corresponda la superficie de la concesión forestal que corresponde a 127.23 ha y la muestra del análisis fue de 25 ha, respectivamente.

3.4. Unidades de muestreo

Las unidades de muestreo corresponden a las áreas de sobrevuelo con el vehículo aéreo tripulado a distancia (RPA), fueron 25 ha de sobrevuelo divididos en 5 parcelas.

3.5. Equipos y materiales

3.5.1. Software

- Agisof Metashape
- Qgis 3.28
- R studio
- Microsoft Word
- Excel
- Power point

3.5.2. Equipos

- Laptop
- GPS Garmin 84 S
- Equipo RPA Phantom 4 Multiespectral

Tabla 1. Especificaciones técnicas del equipo RPA Phantom 4 multiespectral

Aeronave	Especificaciones
Peso de despegue	1487 g
Distancia diagonal (sin incluir hélices)	350 mm
Distancia max. Servicio sobre el nivel del mar	6000 m
velocidad de ascenso máxima	6 m/s (vuelo automático), 5 m/s (control manual)
Velocidad de descenso	3 m/s
Velocidad máxima	50 km/h
Tiempo de vuelo max	27 minutos aprox
Temperatura de funcionamiento	De 0° C a 40° C
Cámara	Especificaciones
Sensores	Seis CMOS de 1/2.9°, incluye un sensor RGB, para imágenes de luz visible, y cinco sensores monocromos para imágenes multiespectrales
Filtros	Azul(B), 450 nm +- 16 nm, Verde (G) 560 nm +- 16 nm, Rojo ®, 650 nm +- 16 nm, Borde rojo (RE) 730 nm +- 16 nm, infrarrojo cercano (NIR) 840 nm +- 26 nm.

3.6. Metodología

3.6.1. Parámetros de vuelo

En la aplicación de DJI GO, se delimito en ámbito de evaluación, para ello se obtuvo los siguientes datos:

Tabla 2. Parámetros de vuelo del equipo RPA

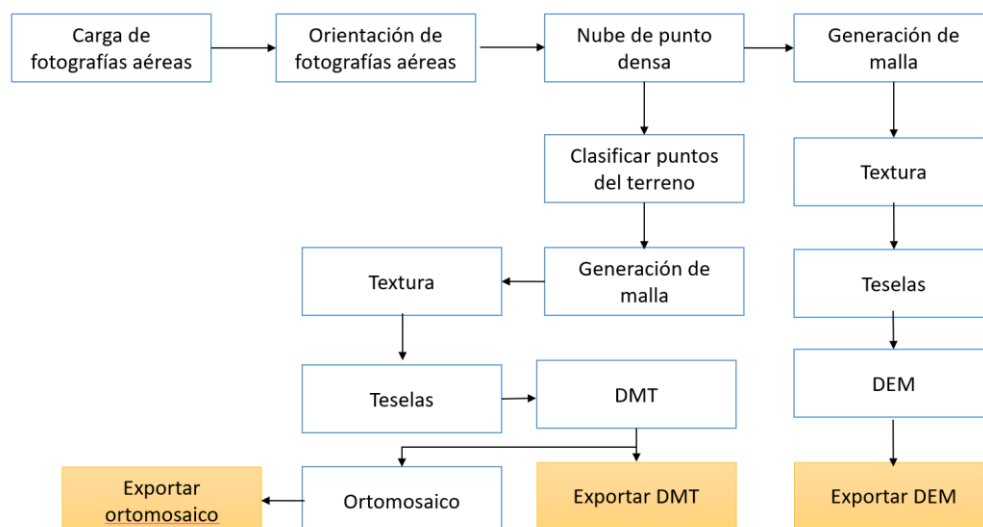
Parámetros	Descripción
Altura	100 metros
Angulo de las líneas de vuelo	Responde según dirección del sol

Cámara	RGB y multiespectral
Overlap	80 %
Velocidad de vuelo	6 km/s
GSD	5 cm

3.6.2. Procesamiento de fotografías aéreas

El procesamiento se realizó en el software Agisoft Metashape; donde se realizan un conjunto de procedimientos para obtener las ortofotos, DEM y DMT; en la siguiente figura 3 explica el proceso metodológico.

Figura 3. Proceso metodológico del procesamiento de fotografías aéreas




3.6.3. Segmentación mediante OBIA (clasificación basada en objetos)

Las bandas de la ortofoto blue-green-red, se subieron en la plataforma de Google Earth Engine, realizando una combinación RGB, de color natural y mediante el algoritmo de segmentación `ee.Algorithms.Image.Segmentation.SNIC`. El algoritmo SNIC, permite la segmentación de superpíxeles con mayor eficiencia computacional, simplicidad de implementación y uso, y control sobre el número y compacidad de los superpíxeles. (Achanta & Sússtrunk, 2017). El SNIC es el más utilizado para la clasificación OBIA, donde el usuario puede optimizar la segmentación ajustando los parámetros de SNIC,

que finalmente genera un archivo ráster multibanda que incluye grupos (objeto segmentado), bandas con ID y bandas que consiste en el promedio de las bandas de entrada sobre cada grupo. El parámetro “seedGrid” en el algoritmo SNIC, determina el tamaño del objeto segmentado, tiene un gran impacto en los resultados de segmentación y, por lo tanto, se necesita ser optimizado (Vizzari, 2022), para el presente estudio elegimos el seedGrid de 3, 5, 10, 15 y 30. Para los demás parámetros elegimos los datos propuestos por (Zheng, y otros, 2022), “compacidad” como 0, “conectividad” como 4 y “neighborhoodSize” como 128.

Figura 4. Segmentación de ortofoto mediante SNIC




3.6.4. Datos de entrenamiento y validación

Se identifican tres tipos de cobertura en el área de estudio: (3) vegetación fotosintéticamente activa (FA), (2) vegetación no fotosintéticamente activa (FNA) y (1) suelo desnudo (S). Todas las muestras de entrenamiento y validación se recopilieron con base en la interpretación visual de las ortofotos. Seleccionamos puntos de entrenamiento, obteniendo un total de 210 puntos de muestreo, donde el 50 % es utilizado para el entrenamiento y el otro 50 % es utilizado para la validación.

3.6.5. Clasificación de Random Forest (RF)

Se utiliza el clasificador de Radom Forest, para determinar las coberturas en el área de estudio, mediante el uso de ortofotos, con base a recomendaciones de estudios previos, seleccionamos 100 árboles de entrenamiento (Phan, Kuch, & Lehnert, 2020) (Cánovas-García, Alonso--Sarría, Gomariz-Castillo, & Oñate-Valdivieso, 2017).


Figura 5. Distribución de puntos de muestreo para el entrenamiento y validación



3.6.6. Evaluación de la precisión del clasificador

Para determinar la precisión del clasificador por tipo de segmentación SNIC, se utiliza métricas extraída de la matriz de confusión como la precisión general y el coeficiente de Kappa. Dichos resultados se

Figura 6. Clasificación de coberturas mediante Radom Forest



obtienen de los puntos de muestreo utilizados para la validación en la plataforma de Google Earth Engine.

3.6.7. Índices de vegetación

Se seleccionan imágenes satelitales Landsat 9; obteniendo índices de vegetación en la plataforma Google Earth Engine, para ello se seleccionan imágenes de la época seca desde el mes de septiembre a octubre, obteniendo un compuesto ráster aplicando la mediana. Los índices de vegetación descritos son: (1) índices convencionales de relación y diferenciales como el NDVI (índice de diferencia normalizada), DVI (índice de vegetación simple) y SR (índice de relación simple); (2) índices ajustados por reflectancia del suelo como el SAVI (índice de vegetación ajustado al suelo), MSAVI (índice de vegetación ajustado al suelo modificado) y OSAVI (índice de vegetación ajustado al suelo optimizado); (3) índices convencionales corregidos y modificados como el RDVI (índice de vegetación de diferencia renormalizada), MSR (índice de relación simple modificada) y GNDVI (índice de vegetación de diferencia normalizada verde).

Tabla 3. Índices espectrales de vegetación

Índice de vegetación	Formula	Referencia
Índices convencionales de relación y diferenciales		
NDVI	$\frac{(nir - red)}{(nir + red)}$	(Rouse, Hass, Schell, & Deering, 1974)
DVI	$nir - red$	(Tucker, 1980)
SR	$\frac{nir}{red}$	(Jordan, 1969)
Índices ajustados por reflectancia de suelo		
SAVI	$(NIR-Rojo/NIR+Rojo+L) \times (1+L)$	(Huete, 1988)
MSAVI	$\frac{2xNIR + 1 - (\sqrt{(2xnir + 1)^2 - 8(nir - red)})}{2}$	(Qi, Huete, Kerr, &

OSAVI	$\frac{(nir - red)}{nir + red + 0.16}$	Sorooshian, 1994) (Rondeux, Steven, & Baret, 1996)
Índices convencionales corregidos y modificados		
RDVI	$(Nir - Red) / \sqrt{Nir + Red}$	(Roujean & Breon, 1995)
MSR	$\frac{(nir/red - 1)}{((nir/red)^{\frac{1}{2}} + 1)}$	(Chen, 1996)
GNDVI	$\frac{(nir - green)}{(nir + green)}$	(Gitelson, Kaufman, & Merzlyak, 1996)

3.6.8. Mapeo de la cobertura leñosa fraccionada

Mediante la clasificación utilizada para determinar la cobertura en el área de estudio, se separa la cobertura leñosa (clases 3 y 2) y la cobertura no leñosa (clase 1), y mediante la fórmula propuesta por (Nasiri, y otros, 2022).

$$FCC(\%) = \frac{\text{Área de vegetación leñosa}}{\text{Área total de la celda}} * 100$$

El tamaño de cada celda corresponde a la cuadrícula de 50 m x 50 m, equivalente a 0.25 ha.

3.6.9. Relación entre FCC y los índices de vegetación

La regresión lineal y el coeficiente de correlación de Pearson se utilizaron para evaluar la relación de la FCC % obtenido mediante las ortofotos de las imágenes aéreas y los índices de vegetación de las imágenes Landsat 9. Todas las muestras de FCC basadas en UAV obtenidos a través del flujo OBIA se superpusieron a los resultados de

los índices de vegetación, extrayendo el valor del pixel. Se utiliza Rstudio para determinar la regresión y correlación.

Las regresiones utilizadas fueron:

Lineal: “ $y \sim a + b \cdot x$ ”

Cuadrática: “ $y \sim a + b \cdot x + c \cdot x^2$ ”

Exponencial: “ $y \sim a \cdot \exp(b \cdot x)$ ”

Cubica: “ $y \sim a + b \cdot x + c \cdot x^2 + d \cdot x^3$ ”

Regresión lineal múltiple : “ $y \sim B_0 + B_1X_1 + B_2X_2 + B_nX_n$ ”

Para determinar la precisión de los modelos de regresión se obtuvo el error cuadrático medio RMSE y el error absoluto medio (MAE), mediante la siguientes formulas:

$$MAE : \frac{\sum_{n:1}^N |\hat{r}_n - r_n|}{N}$$

$$RMSE : \sqrt{\frac{\sum_{n:1}^N (\hat{r}_n - r_n)^2}{N}}$$

Donde:

\hat{r}_n : Calificación de la predicción.

r_n : Calificación real en el conjunto de datos de prueba

N : Numero de pares de calificación entre los datos de prueba y los resultados de predicción

3.6.10. Análisis multitemporal de los cambios en la cobertura fraccional

Se analiza los cambios en la cobertura fraccional utilizando el modelo con mayor correlación; para las imágenes históricas del periodo 1990, 2000, 2014, 2018 y 2024, respectivamente. Con ello identificaremos, los cambios en la cobertura vegetal con respecto al porcentaje de la cubierta forestal, y relacionamos los cambios con respecto a la

precipitación histórica registrado en la estación meteorológica de Puerto Pizarro, como se describe en la tabla 4.

Tabla 4. Datos de la estación meteorológica de Puerto Pizarro

Estación : PUERTO PIZARRO					
Departamento :	TUMBES	Provincia :	TUMBES	Distrito :	TUMBES
Latitud :	3°30'13.67"	Longitud :	80°23'42.14"	Altitud :	6 msnm.
	CO -				
Tipo :	Meteorológica	Código :	103038		

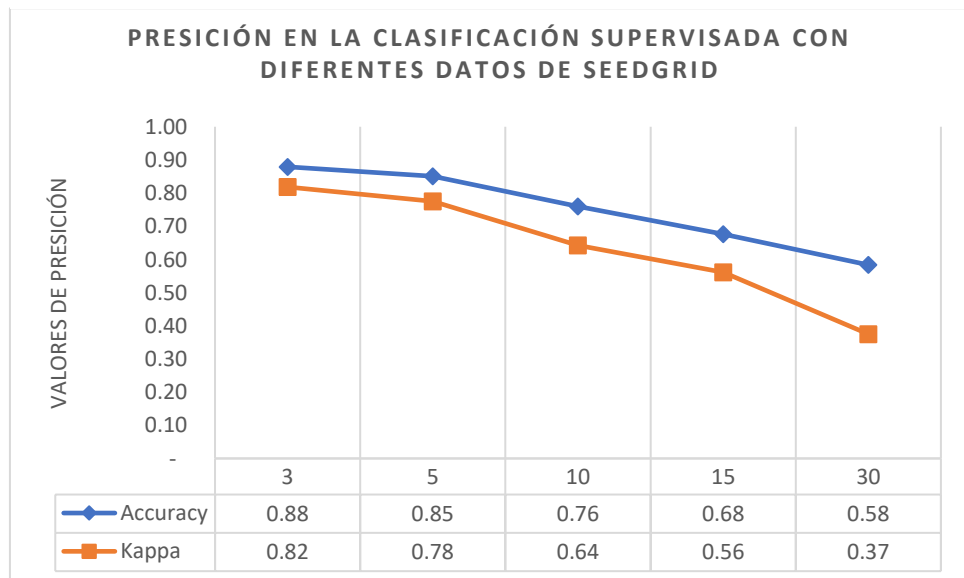
IV.RESULTADOS Y DISCUSIONES

4.1. Clasificación de la cobertura vegetal del área de estudio, aplicando el clasificador de Random Forest.

Los procesos para evaluar las combinaciones de la clasificación de objetos OBIA, mediante el algoritmo SNIC, con las combinaciones de seedGrid de 3, 5, 10, 15 y 30, donde el resto de parámetros que utilizamos son los mismos para cada análisis “compacidad” como 0, “conectividad” como 4 y “neighborhoodSize” como 128.

El seedGrid, consiste en la agrupación de pixeles, cuando menor es esta agrupación mejor son los resultados en la clasificación; la figura , se observa que los valores de seedGrid tiene mayor precisión en las métricas de accuracy y kappa en los valores de seedGrid de 3 y 5 con valores de 0.88, 0.82 y 0.85, 0.78, con respecto a los valores de seedGrid de 10, 15 y 30, donde obtienen una precisión en de accuracy y kappa de 0.76, 0.64; 0.68, 0.56 y 0.58, 0.37, respectivamente


Figura 7. Precisión en la clasificación supervisada con diferentes datos SEEDGRID



La segmentación es demasiado fragmentada si la semilla (seed), se elige demasiado pequeña, por lo que puede llevar a una clasificación mixta, mientras si la semilla se elige demasiado grande, los objetos por la segmentación sean grandes conllevando a una segmentación incorrecta, En el caso del presente estudio la semilla de 3 a 5, produce resultados fehacientes con respecto a la clasificación supervisada; dichos datos difiere al estudio de Zheng, y otros, (2022), quienes precisan en su estudio que el seedGrid de 48 tiene la mejor segmentación en comparación al seedGrid de 36 y 60.


Con respecto al clasificador Random Forest hemos obtenido exactitudes, relativamente positivas, con un coeficiente de Kappa de 0.82, para ecosistemas áridos como el bosque seco, estudios relacionados confirman la capacidad del clasificador de Random Forest en imágenes RGB de alta resolución de vehículos aéreos tripulados a distancia para clasificar y estimar la cobertura vegetal; (Xie, y otros, 2022), utilizaron imágenes RGB de dos periodos, 2006 y 2019, con una resolución de 0.1 m, capturadas con vehículo aéreo no tripulado (UAV), donde el clasificador Random Forest obtuvo las mejores precisiones durante la clasificación de la cobertura fraccional. (Campos-Vargas, Sanchez-Azofeifa, Laakso, & Marzahn, 2020), aplicaron diez técnicas de aprendizaje automático en datos multiespectrales de vehículos aéreos no tripulados (UAV), donde evaluaron la precisión y tiempo de procesamiento, donde la máquina de vectores de soporte con núcleo radial (SVMR) y Random forest (RF) proporcionaron las mejores precisiones. Finalmente deducimos que el clasificador Random Forest tiene la capacidad de estimar la cobertura vegetal en ecosistemas de bosque seco. Se muestra en la figura 8 y 9, mapas de clasificación de cada parcela de evaluación.

Figura 8. Clasificación supervisada Random Forest y ortomosaico RGB en parcela 1, 2 y 3



Nota: (A) clasificación supervisada en parcela 1, (B) ortomosaico RGB en parcela 1, (C) clasificación supervisada en parcela 2, (D) ortomosaico RGB en parcela 2, (E) clasificación supervisada en parcela 3, (F) ortomosaico RGB en parcela 3.

Figura 9. Clasificación supervisada Random Forest y ortomosaico RGB en parcela 4 y 5




Nota: (A) clasificación supervisada en parcela 4, (B) ortomosaico RGB en parcela 4, (C) clasificación supervisada en parcela 5, (D), ortomosaico RGB en la parcela 5

4.2. Correlación de índices de vegetación y cobertura fraccional (FCC)

La cobertura fraccional abarca toda la vegetación leñosa, donde incluye árboles y arbustos, se relaciona con valores de índices de vegetación en sus diferentes clases; (1) índices convencionales y diferenciales, (2) índices corregidos y derivados de los índices tradicionales y (3) índices ajustados por reflectancia al suelo, en la siguiente figura 10, muestra la correlación de pearson en una regresión lineal entre todas las variables y: FC y X: NDVI, SAVI, OSAVI, MSAVI, RDVI, DVI, MRS, SR, respectivamente.

Figura 10. Coeficiente de pearson de la regresión lineal de todas las variables



La mejor relación entre fracción de cobertura (FC) e índices de vegetación, se muestra en la regresión lineal entre (FC, NDVI), (FC, OSAVI), (FC, MRS) y (FC, SR), con valores de correlación de Pearson (r) de 0.78, 0.78, 0.77 y 0.77; pero no es lo suficiente para tener datos que se relacionen efectivamente a la realidad del terreno, por ende, se utilizan otros modelos de regresión como el exponencial, cuadrática y cubica, obteniendo las siguientes métricas de (R) y (R²), en las tablas 2, 3 y 4.

Tabla 5. Métricas de precisión en índices convencionales y diferenciales

Método	NDVI		SR		DVI	
	R	R ²	R	R ²	R	R ²
Lineal	0.78	0.60	0.77	0.60	0.53	0.28
Cuadrática	0.78	0.61	0.78	0.61	0.61	0.38
Exponencial	0.77	0.59	0.76	0.58	0.51	0.26
Cubica	0.80	0.64	0.80	0.63	0.61	0.38

Tabla 6. Métricas de precisión en índices ajustados por reflectancia del suelo

Método	SAVI		OSAVI		MSAVI	
	R	R ²	R	R ²	R	R ²
Lineal	0.69	0.48	0.78	0.62	0.64	0.41
Cuadrática	0.75	0.57	0.80	0.64	0.72	0.51
Exponencial	0.67	0.45	0.77	0.59	0.62	0.38
Cubica	0.75	0.57	0.80	0.65	0.72	0.51

Tabla 7. Métricas de precisión en índices convencionales corregidos y modificados

Método	GNDVI		MRS		RDVI	
	R	R ²	R	R ²	R	R ²
Lineal	0.75	0.57	0.77	0.60	0.74	0.54
Cuadrática	0.76	0.57	0.78	0.61	0.78	0.61
Exponencial	0.75	0.56	0.77	0.59	0.72	0.51
Cubica	0.77	0.59	0.80	0.64	0.78	0.61

Los modelos de correlación señalan que todos los índices de vegetación tienen mayor precisión en la regresión cubica , muchos estudios indica que la alta precisión de la regresión cubica en predecir factores relacionados a la cobertura terrestre, tal como (Xu, y otros, 2023); quien obtuvo el mejor ajuste entre fracción de la cobertura del dosel e índices de vegetación como el NDVI

y NSVI (índice de vegetación sombreada normalizada), en los modelos cúbicos; Otro caso relacionado es la investigación de (Vatandaşlar & Yavuz, 2017); quien relaciono el NDVI para calcular el factor de gestión de cobertura (C), modelo de predicción de erosión, utilizando imágenes satelitales World View , según sus resultados indican que el modelo cubico tuvo el mejor desempeño; (Vigabriel Navarro, Osorio Leyton, Quezada Lambertin, & Benavides Lopez, 2024); encontraron una alta correlación en una regresión cubica entre biomasa de cebada y NDVI. Estos resultados indican que el modelo de regresión no lineal específicamente la regresión cubica, predice con mayor exactitud los parámetros relacionados a la cobertura terrestre tal como la fracción de cobertura del dosel (FC), grado de erosión y biomasa.

Los índices que predice con mayor exactitud los valores de la fracción de la cobertura vegetal (FC), es el NDVI y OSAVI; mediante regresiones cubicas se obtiene un coeficiente de determinación de 0.64 y 0.645, con errores MAE de 5.5 % y 5.4 %; y errores RMSE de 6.6 % y 6.5 %, respectivamente. En la tabla 8 muestra las ecuaciones y presiones de la regresión de FC y NDVI, OSAVI; en las figuras 11 y 12, muestra la curva de regresión cubica entre FC y NDVI; FC y OSAVI.

Tabla 8. Modelos de regresión cubica entre FC y NDVI, OSAVI

Índices	Ecuación	R	R ²	MAE	RMSE
NDVI	$Y = 49.962 - 554.953 * x + 2054.303 * x^2 - 2499.949 * x^3$	0.8	0.64	5.50%	6.60%
OSAVI	$Y = 17.577 - 314.776 * x + 1879.005 * x^2 - 3612.404 * x^3$	0.8	0.645	5.40%	6.50%

Figura 11. Regresión cubica entre FC y NDVI





Figura 12. Regresión cubica entre FC y OSAVI



Se muestra en la tabla 8, que la relación entre FC, NDVI y OSAVI, no existe diferencias significativas en relación a las métricas de precisión de ambos modelos, y son los mejores índices para predecir la cobertura fraccional en un bosque seco, estudios indican, que la relación entre índices convencionales e índices ajustados al suelo, presentan valores en la

métricas de precisión considerablemente positivos (Wang, y otros, 2022) (Barati, Rayegani, Saati, Sharifi, & Nasri, 2011). Esto se debe principalmente que el NDVI absorbe las ondas electromagnéticas en la región roja por la clorofila y su alta reflectancia en la región infrarrojo cercano (Tucker, 1980), y son las razones de obtener un coeficiente considerable; estudios señalan la utilidad del NDVI en la detección de cobertura fraccional, tal como (Scanlon, Albertson, Caylor, & Williams, 2002), quienes utilizaron el NDVI para estimar la cobertura fraccional en función a las diferentes formas en que los árboles y pastos responden a las precipitaciones, obteniendo regresiones que alcanzan un coeficiente de determinación de R^2 0.87. (Chu, 2019), menciona que logro obtener un coeficiente de determinación $R^2 = 0.90$, en la relación de NDVI y cobertura vegetal fraccionada en la meseta tibetana central. El OSAVI es una alternativa reciente que puede adaptarse a una mayor variabilidad debido a los altos valores de fondo del suelo, y es un buen estimador de biomasa y cobertura vegetal (Fern, Foxley, Bruno, & Morrison, 2018). Para estimar la fracción de cobertura vegetal, se puede utilizar la ecuación generada por la regresión cubica del NDVI y OSAVI.

Aunque el NDVI y el OSAVI, son los índices de mayor precisión para determinar la fracción de cobertura del dosel, es importante generar regresiones que mejoren las precisiones; por lo tanto, se ha desarrollado modelos de regresión lineal múltiple para utilizar información de diferentes índices.

Tabla 9. Modelos de regresión lineal múltiple para predecir FC

Modelos	Ecuación	R	R2	MAE	RMSE
Modelo 1	$Y = 852.396 - 531.31 \text{ SAVI} + 289.199 \text{ OSAVI} - 123.693 \text{ MSAVI} - 2861.907 \text{ NDVI} + 615.654 \text{ RDVI} + 2981.457 \text{ MRS} - 2.186 \text{ GNDVI} - 836.887 \text{ SR}$	0.8283	0.6861	5.18%	6.16%
Modelo 2	$Y = 924.070 - 2918.438 \text{ NDVI} + 3.438 \text{ RDVI} + 3226.625 \text{ MRS} - 906.995 \text{ SR}$	0.8247	0.6802	5.24%	6.22%
Modelo 3	$Y = 905.127 - 18.010 * \text{SAVI} - 2859.533 * \text{NDVI} + 28.005 * \text{RDVI} + 3159.900 * \text{MRS} - 1.965 * \text{GNDVI} - 888.238 * \text{SR}$	0.8275	0.6848	5.19%	6.17%

En la tabla 9, se muestra los modelos de regresión lineal múltiple, donde el modelo 1, presenta las mejores precisiones en cuanto al coeficiente de determinación $R^2 = 0.686$, y errores de MAE = 5.18 % y RMSE 6.16 %, respectivamente.

Aunque la regresión múltiple genera mejores precisiones en la estimación de la fracción de cobertura vegetal que por separado, tal como (Barati, Rayegani, Saati, Sharifi, & Nasri, 2011); quien es su estudio confirma el uso de la regresión múltiple en generar coeficientes más precisos en comparación a regresiones individuales obteniendo un valor de $R^2 = 0.797$, en nuestra investigación no se encontró diferencia significativa con las regresiones individuales como las cubicas.


4.3. Análisis multitemporal mediante imágenes satelitales Landsat

La estimación de la fracción de cobertura vegetal se obtiene mediante la regresión lineal múltiple del modelo 1, $Y = 852.396 - 531.31*SAVI + 289.199*OSAVI - 123.693*MSAVI - 2861.907*NDVI + 615.654*RDVI + 2981.457*MRS - 2.186*GNDVI - 836.887*SR$. Y se establece una clasificación basada en (Zhang, Zhang, & Singh, 2024), se muestra en la tabla 10:

Tabla 10. Valor de fracción de la cobertura vegetal (FCV)

Valor de FCV	Categorías
0.00 <= FVC < 0.3	Cobertura extremadamente baja
0.30 <= FVC < 0.45	Baja cobertura
0.45 <= FVC < 0.60	Cobertura media
0.60 <= FCV < 0.75	Cobertura media - alta
0.75 <= FCV < 1.00	Alta cobertura vegetal

Figura 13. Fracción de la cobertura vegetal en el área de estudio



Nota: A) Fracción cobertura vegetal de 0 – 0.30, 0.45 – 0.60 y 0.60 – 0.75; B) Imagen satelital en la posición de A; C) Fracción cobertura vegetal de 0.30 – 0.45, 0.45 – 0.60, 0.60 – 0.75 y 0.75 – 1; D) Imagen satelital en la posición de C; E) Fracción cobertura vegetal de 0.45 – 0.60, 0.60 – 0.75 y 0.75 – 1.00; F) Imagen satelital en posición de E.

Es importante señalar que la fracción de la cobertura vegetal es la cobertura de vegetación fotosintéticamente activa y vegetación no fotosintética, según la clasificación establecida en las figuras 8 y 9. Ante ello debido a la

presencia en el área de estudio de árboles y arbustos en estado de defoliación, tienen la misma firma espectral y durante la clasificación es seleccionado como un solo estrato, (Nasiri, y otros, 2022), indica que la fracción de la cobertura vegetal basado en índices de vegetación esta influenciado por la salud del bosque, biomasa de los árboles, densidad de follaje, contenido de clorofila y el estrés hídrico; por ende se presenta una sobrestimación de la cobertura del dosel, debido al parecido de las firmas espectrales entre arbustos y árboles, dichos resultados es afirmado (Godingo, Guiomar, & Gil, 2018) , menciona que las predicciones del modelo presentan una sobreestimación de algunos pixeles , debido a que los resultados parte significativa del sotobosque que también está cubierta por arbustos de hoja perenne e influye en los porcentajes de cobertura del dosel . (Bolaf-Mena, Tanase, & Gómez-Sal, 2019), en su investigación determino que los sensores remotos son óptimos para la extracción de cobertura arbórea , los resultados mostraron que las técnicas basadas en RGB pueden lograr tener resultados precisos, sin embargo, la extracción basada en sensores ópticos es vulnerable a la confusión entre árboles y arbustos. La extracción de la cubierta arbórea a partir de ortofotos dio resultados con precisiones razonables, sin embargo, presenta errores de comisión causado por la presencia de vegetación baja, estanques y caminos. Por lo tanto, la firma espectral de los pixeles de arbustos y arboles contribuirán a una sobrestimación de la cobertura del dosel, debido que no solamente cuantificará las copas de los árboles sino también de los arbustos.

Posteriormente se obtiene la fracción de la cobertura del dosel para los años 1986, 1999, 2014 y 2024, como se muestra en los cuadros 11, 12 y 13.

Tabla 11. Cambios de la fracción de cobertura vegetal periodo 1986 - 1999

FC_1986	FC_1999					Total general	Perdida	Ganancia
	Cobertura alta	Cobertura baja	Cobertura extremadamente baja	Cobertura media	Cobertura media alta			
Cobertura baja	2.093	0.019				2.112		2.093
Cobertura alta	0.039					0.039		
Cobertura extremadamente baja	103.051	0.394	0.358	6.246	13.652	123.700		123.343
Cobertura media	1.061				0.090	1.151		1.151
Cobertura media alta	0.029					0.029		0.029
Total general	106.273	0.413	0.358	6.246	13.742	127.031	-	126.616

La fracción de la cobertura vegetal para los años de 1986 – 1999, según la tabla 11, presenta una ganancia de aproximadamente 126.616 ha, con respecto a las categorías establecidas, indicando una recuperación de la vegetación, obteniendo una transición de 2.093 ha de cobertura baja – cobertura alta, 103.05 ha de cobertura extremadamente baja – cobertura alta, 0.394 ha de cobertura extremadamente baja – cobertura baja, 6.246 ha de cobertura extremadamente baja – cobertura media y 13.652 ha de cobertura extremadamente baja – cobertura media alta, 1.061 ha de cobertura media – cobertura alta, 0.090 ha de cobertura media – cobertura media alta, respectivamente.

Tabla 12. Cambios de la fracción de cobertura vegetal periodo 1999 - 2014

FC_1999	FC_2014				Total general	Perdida	Ganancia
	Cobertura alta	Cobertura baja	Cobertura media	Cobertura media alta			
Cobertura alta	1.448	41.982	49.045	13.799	106.273	104.825	
Cobertura baja		0.413			0.413		
Cobertura extremadamente baja		0.358			0.358		0.358
Cobertura media		5.841	0.361	0.044	6.246	5.841	0.044

Cobertura media alta		10.284	3.188	0.270	13.742	13.472	
Total general	1.448	58.876	52.594	14.113	127.031	124.138	0.401

La fracción de la cobertura vegetal para los años 1999 – 2014, según tabla 12, presenta una pérdida de 124.13 ha, de acuerdo a las categorías establecidas indica una degradación en el área de estudio, obteniendo transiciones de 41.98 ha de cobertura alta – cobertura baja, 49.04 ha de cobertura alta - cobertura media, 13.79 ha de cobertura alta – cobertura media alta, 5.84 ha cobertura media – cobertura baja, 10.28 ha de cobertura media alta – cobertura baja, 3.18 ha de cobertura media alta – cobertura media. En el caso de las ganancias se obtiene un valor de 0.40 ha, indica una superficie en proceso de recuperación en las transiciones de cobertura extremadamente baja – cobertura baja con 0.36 ha y cobertura media a cobertura media alta con 0.04 ha, respectivamente.

Tabla 13. cambios de la fracción de cobertura vegetal periodo 2014 - 2024

FC_2014	FC_2024						Perdida	Ganancia
	Cobertura alta	Cobertura baja	Cobertura extremadamente baja	cobertura media	Cobertura media alta	Total general		
Cobertura alta	1.448					1.448		
Cobertura baja	5.012	2.730	1.200	27.715	22.220	58.876	1.200	54.947
Cobertura media	24.875	0.360		4.042	23.317	52.594	0.360	48.192
Cobertura media alta	13.421				0.691	14.113		13.421
Total general	44.757	3.090	1.200	31.757	46.229	127.031	1.5600	116.561

La fracción de la cobertura vegetal para los años 2014 – 2024, según la tabla 13, presenta una pérdida de 1.560 ha, de acuerdo a las categorías establecidas indica una degradación en el área de estudio, obteniendo transiciones de cobertura baja – cobertura extremadamente baja de 1.20 ha, cobertura media – cobertura baja de 0.36 ha. En el caso de las ganancias se obtiene una superficie de 116.56 ha, indica que el ámbito de estudio se encuentra en proceso de recuperación, los cambios se observan en las

transiciones de cobertura baja – cobertura alta con 5.01 ha, cobertura baja – cobertura media con 27.72 ha, cobertura baja – cobertura baja media con 22.22 ha, cobertura media a cobertura alta con 24.88 ha, cobertura media – cobertura media alta con 23.32 ha, cobertura media alta – cobertura alta con 13.421.

Tabla 14. Cambios de la fracción de cobertura vegetal periodo de 1986 - 2024

FC_1986	FC_2024						Perdida	Ganancia
	Cobertura alta	Cobertura baja	Cobertura extremadamente baja	Cobertura media	Cobertura media alta	Total general		
Cobertura baja	1.463				0.649	2.112		2.112
Cobertura alta					0.039	0.039	0.039	
Cobertura extremadamente baja	42.232	3.090	1.200	31.757	45.422	123.700		122.501
Cobertura media	1.061				0.090	1.151		1.061
Cobertura media alta					0.029	0.029		
Total general	44.757	3.090	1.200	31.757	46.229	127.031	0.039	125.674


En general, para el periodo de estudio de 1986 hasta 2024, la tabla 14, señala que hubo una recuperación de 125.67 ha, según lo establecido en las categorías de fracción de la cobertura vegetal, donde indica que la recuperación se dio en cobertura baja – cobertura media alta con 0.649 ha, cobertura extremadamente baja – cobertura alta con 42.23 ha, cobertura extremadamente baja – cobertura baja con 3.09 ha, cobertura extremadamente baja – cobertura media con 31.76 ha, cobertura extremadamente baja – cobertura media alta con 45.42 ha, cobertura media – cobertura alta con 1.06 ha, cobertura media – cobertura media alta con 0.09 ha. Con respecto a la perdida se dio en la transición de cobertura alta – cobertura media alta con 0.65 ha, respectivamente.

Los resultados muestran un incremento de la fracción de la cobertura vegetal, desde 1986 al 2014, siendo un indicador que nos permite determinar los cambios en la cobertura vegetal influenciada por actividades

antropogénicas y variables climáticas, permitiendo determinar el grado de degradación o recuperación en el ámbito de estudio; así lo señala, (Cai, y otros, 2022); quien utilizó la fracción de cobertura vegetal como indicador para determinar la restauración de tierras por programas de forestación en china, obteniendo tasas altas en los cambios, (Matricardi, Skole, Pedlowski, Chomentowski, & Fernandes, 2010), utilizaron la cobertura fraccional, para determinar los impactos de la tala selectiva y los incendios forestales en la selva tropical brasileña, determinando que la fracción de cobertura derivada de índice de vegetación e imágenes Landsat TM y ETM+, demostró ser un enfoque preciso y eficiente para medir la degradación y regeneración forestal.

La fracción de cobertura, se ve influenciada por las variables climáticas, así lo señala las tablas, 11, 12 y 13, donde inicialmente en el periodo 1986 al 1999, los cambios en las transiciones de las categorías de la cobertura fraccional son de ganancia en más de 126 ha, relacionándose con las precipitaciones pluviales, donde se registró para los años de 1997, 1998 y 1999 lluvias de 1054.7 mm/año, 2433.6 mm/año y 401.7 mm/año. La figura 14, muestra una serie de tiempo entre precipitaciones y NDVI para el periodo 1986 – 1999, donde la mediana de la precipitación en este periodo es de 290.90 mm/año y para el NDVI es de 0.193; la variabilidad se muestra cuando aumenta las precipitaciones en el año 1998 donde registra una precipitación de 2433.6 mm/año y NDVI de 0.683, a pesar que en el año 1997, registra una precipitación de 1054.7 mm/año, el valor de NDVI es incluso menor a la mediana con 0.176, respectivamente.

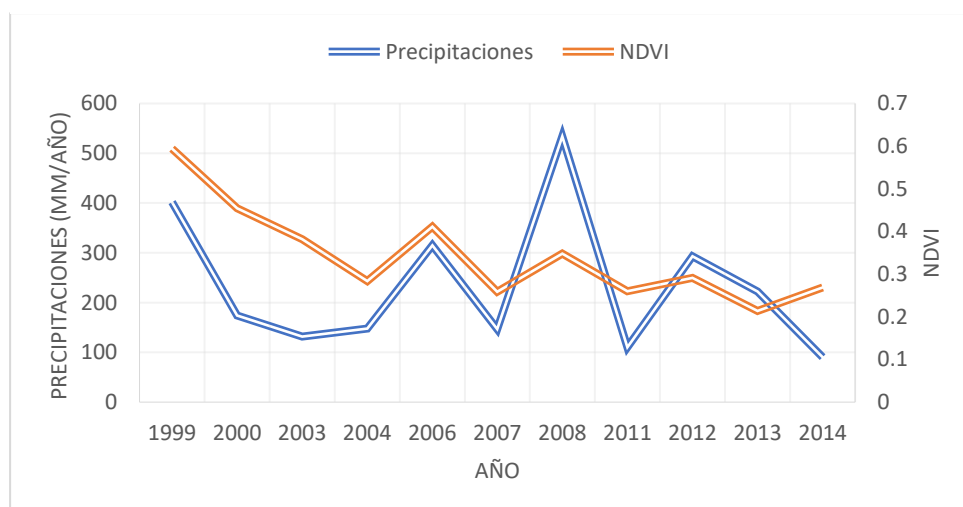
Figura 14. Serie de tiempo entre precipitación (mm/año) y NDVI durante el periodo de 1986 - 1999



Nota: precipitaciones anuales obtenidas en la estación meteorológica Puerto Pizarro.
Fuente: SENAMHI

El periodo de 1999 al 2014, la cobertura fraccional tuvo una pérdida de 124 ha aproximadamente, esto podría ser causa a las diversas acciones antrópicas como la tala selectiva y sobrepastoreo en sinergia de lluvias leves donde se registraron precipitaciones en los años 2012, 2013 y 2014 de 293.1 mm/año, 222 mm/año y 90.3 mm/año. La figura 16, muestra una serie de tiempo entre precipitación y NDVI durante el periodo de 1999 y 2014, donde la mediana de la precipitación es de 174.2 mm/año y NDVI de 0.291, se considera un periodo de lluvias normales, por ende, los valores de NDVI no presenta diferencia significativa. Sin embargo, las lluvias más intensas que se registran 401.7 mm/año y 533.8 mm/año en los años 1999 y 2008 presentan valores de NDVI de 0.594 y 0.348 similar a los años que registran lluvias menores de 174.2 mm/año y 131.8 mm/año en los años 2000 y 2003,m, presentan valores de NDVI de 0.454 y 0.381. En el año 2014, donde se registró la precipitación más baja durante el periodo de estudio con 90.30 mm/año, con valores de NDVI de 0.268, superior incluso en años con precipitaciones de 146.90 y 222.00 en los años 2017 y 2013, donde obtuvieron valores de NDVI 0.258 y 0.213, respectivamente.


Figura 15. Serie de tiempo entre precipitación (mm/año) y NDVI durante el periodo de 1999 - 2014



Nota: precipitaciones anuales obtenidas en la estación meteorológica Puerto Pizarro. Fuente: SENAMHI


El periodo de 2014 al 2024, la cobertura fraccional tuvo una ganancia de aproximadamente 116 ha, podría estar relacionado al incremento de cobertura leñosa, árboles y arbustos por las diferentes actividades de recuperación forestal por parte de la Universidad Nacional de Tumbes en sinergia con las precipitaciones registradas en los años 2017, 2018, 2019 y 2020 de 817 mm/año, 280.42 mm/año, 248.30 mm/año y 282.60 mm/año, respectivamente. De acuerdo a los datos la mediana de precipitación durante este periodo es de 281.51 mm/año y el valor de NDVI de 0.375. La figura 17, se aprecia un incremento de NDVI de 0.559 en el año 2017, donde presenta lluvias de 817 mm/año, el resto de años las precipitaciones se encuentran normalizadas, debido a que los valores se encuentra muy cerca a la mediana, así como los valores de NDVI, sin embargo años con precipitaciones bajas presentan 90.30 mm/año y 75.80 mm/año, en los años 2014 y 2023, presenta valores en el NDVI de 0.268 y 0.370, valores muy cercanos a años de lluvias más fuertes como el año 2015, 2018 y 2020 con precipitaciones de 315.91 mm/año, 280.42 mm/año y 282.60 mm/año y valores de NDVI de 0.303, 0.313 y 0.371, respectivamente.

Figura 16. Serie de tiempo entre precipitaciones (mm/año) y NDVI durante el periodo 2014 - 2024



Nota: precipitaciones anuales obtenidas en la estación meteorológica Puerto Pizarro.
Fuente: SENAMHI

Figura 17. Serie de tiempo entre precipitaciones (mm/año) y NDVI durante el periodo 1986 - 2024



Es importante precisar la interferencia de las precipitaciones pluviales en la detección de la fracción de cobertura vegetal, debido que predice valores erróneos, debido principalmente que los índices de vegetación son sensibles

al aumento de biomasa verde, específicamente de herbáceas y arbustos, esto se observa durante el año de fenómeno del Niño, 1997, 1998 y 2017, así lo menciona (Roque Quiroz, 2022), en su estudio denominado tendencia del NDVI en el Área de Conservación Regional Angostura Faical de Tumbes, Perú, 1999 – 2019, indica que la presencia del fenómeno El Niño en la región de Tumbes, ocasiona dinamismo en la cobertura vegetal; (Campaña-Olaya & Gines Tafur, 2021), describe que la vegetación alta “bosque”, en la Reserva Nacional de Tumbes, registro el mayor valor en el año 1986, después del fenómeno El Niño, alcanzando a cubrir aproximadamente el 99 % del área total. Sin embargo, cuando las lluvias son normales o incluso en épocas de sequía, el NDVI no presenta una variabilidad significativa, esto es debido al efecto acumulativo de las precipitaciones como se muestra en los años de 1999, donde las precipitaciones son de 401.70 mm/año y su valor de NDVI es de 0.594, debido a que recibió el efecto acumulativo del año 1998. A diferencia del año 1997 que a pesar de haber registrado una precipitación de 1054.70 (mm/año), registra un valor de 0.176, muy probable dependa por un exceso de agua que afecta el crecimiento de la vegetación y follaje, estos resultados se relaciona al estudio de (Escate Buitrón, y otros, 2024), donde correlaciono data estadística de venado cola blanca y los niveles de vigorosidad vegetal mediante el NDVI , data meteorológica en el ANP Coto de Caza El Angolo, encontró valores máximos de NDVI registrados en los años de 1987 y 2023 y recibió una precipitación de 500 y 700 mm, difieren de los datos de 1997-1998 que supera los 3000 mm, obteniendo un NDVI menor, debido al exceso de agua que supera los umbrales de desarrollo fenológico, que tanto la carencia y excesos afecta al crecimiento de la vegetación.

Finalmente, demostramos que la fracción de la cobertura vegetal, se ve influenciado por la variabilidad climática del bosque seco, específicamente en el área de estudio, las lluvias fuertes alteran los valores de los índices de vegetación y presenta un efecto acumulado para los años posteriores, generando predecir erróneamente la fracción de la cobertura vegetal.

V. CONCLUSIONES

- La clasificación supervisada mediante el algoritmo de Random Forest presenta una alta exactitud con valores Kappa de 0.82 y 0.78, cuando el tamaño del segmento seedGrid de 3 y 5, utilizando fotografías aéreas de alta resolución, permitiendo clasificar la cobertura en vegetación fotosintéticamente activa, vegetación no fotosintética y suelo desnudo, en un área de bosque seco.
- La correlación de los índices de vegetación y fracción de la cobertura vegetal señala que los modelos cúbicos, presenta mayor correlación, siendo el índice del NDVI y OSAVI con valores de R^2 de 0.64 y 0.645, donde obtuvieron la mayor correlación, logrando estimar la fracción de la cobertura vegetal con errores RMSE y MAE de 6.60 % y 6.50 % ; 5.50 % y 5.40 %, respectivamente. Sin embargo, la correlación múltiple genera un ligero incremento en R^2 , con valor de 0.6861, con respecto al modelo 1 y errores de RMSE y MAE de 6.17 % y 5.19 %.
- En el análisis histórico de la fracción de la cobertura vegetal, tiene una tendencia de incremento, influenciada por el aumento de la cobertura leñosa, sin embargo, en años anómalos, donde se presenta lluvias intensas como fenómeno El Niño, genera errores en el modelo y no se recomienda para la estimación y predicción de la fracción de la cobertura vegetal, debido que será influenciada por vegetación fotosintéticamente activa (árboles, arbustos y herbáceas).

VI.RECOMENDACIONES

- Se recomienda el uso de fotografías aéreas mediante vehículo aéreos tripulados a distancia, para determinar fenologías de especies forestales, cambios en la biomasa y efecto de la tala selectiva.
- Se sugiere la aplicación de otros índices de vegetación a parte de los utilizados en la presente investigación para relacionar con la fracción de la cobertura vegetal.

VII. REFERENCIAS BIBLIOGRAFICAS

- Achanta, R., & Sússtrunk, S. (2017). Superpixels and Polygons using Simple Non-Iterative Clustering. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 4651-4660.
- Aguirre Padilla, N., Alvarado Espejo, J., & Granda Pardo, J. (2018). Bienes y servicios ecosistémicos de los bosques secos de la provincia de Loja. *Bosques Latitud Cero*, 8(2), 118 - 130. Obtenido de <https://revistas.unl.edu.ec/index.php/bosques/article/view/499/394>
- Angulo, F. (2009). Los bosques secos del noroeste del Perú: una invitación a la reflexión. *Xilema*.
- Barati, s., Rayegani, B., Saati, M., Sharifi, A., & Nasri, M. (2011). Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas. *The Egyptian Journal of Remote Sensing and Space Science*, 14(1), 49-56. doi:<https://doi.org/10.1016/j.ejrs.2011.06.001>
- Bolaf-Mena, I., Tanase, M., & Gómez-Sal, A. (2019). Methods for tree cover extraction from high resolution orthophotos and airborne LiDAR scanning in Spanish dehesas. *Revista de teledetección*, 50, 17-32. doi:<https://doi.org/10.4995/raet.2019.11320>
- Cai, Y., Zhang, F., Duan, P., Jim, C., NW, C., Shi, J., . . . Ma, X. (2022). Vegetation cover changes in China induced by ecological restoration -protectio projects and land - use changes from 2000 to 2020. *Catena*, 217, 106530. doi:<https://doi.org/10.1016/j.catena.2022.106530>
- Campaña-Olaya, J., & Gines Tafur, E. (2021). Análisis multitemporal mediante SIG de la sequia y la deforestación en la Reserva Nacional de Tumbes - Perú, 1986 - 2019. *Manglar*, 267-274. doi:<https://doi.org/10.17268/manglar.2021.035>
- Campos-Vargas, C., Sanchez-Azofeifa, A., Laakso, K., & Marzahn, P. (2020). Unmanned Aerial System and Machine Learning Techniques Help to Detect

- Dead Woody Components in a Tropical Dry Forest. *Forest*, 11(8), 827.
doi:<https://doi.org/10.3390/f11080827>
- Cánovas-García, F., Alonso--Sarría, F., Gomariz-Castillo, F., & Oñate-Valdivieso, F. (2017). Modification of the random forest algorithm to avoid statistical dependence problems when classifying remote sensing imagery. *Computers & Geosciences*, 103, 1-11. Obtenido de <https://doi.org/10.1016/j.cageo.2017.02.012>
- Chen, J. (1996). Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Canadian Journal of Remote Sensing*, 22(3), 229-242.
doi: <https://doi.org/10.1080/07038992.1996.10855178>
- Chu, D. (2019). Fractional Vegetation Cover. *Remote Sensing of Land Use and Land Cover in Mountain Region*, 195-207.
- Escate Buitrón, K., Caldas Zumaran, N., Ávila Apuy, A., Mendoza Manturano, B., Colonna Montero, J., & Giraldo Malca, U. (2024). Impacto de las sequias y el Niño Costero en el bsoque seco y el venado cola blanca en el Coto de Caza El Angolo - Perú.
- FAO. (2016). *Los bosques y el cambio climático en el Perú*. Roma: Organización de las Naciones Unidas para la Alimentación y la Agricultura. Obtenido de <https://openknowledge.fao.org/server/api/core/bitstreams/ec0e1252-1295-4058-8c2b-e6d06b49f419/content>
- Fern, R., Foxley, E., Bruno, A., & Morrison, M. (2018). Sutability of NDVI and OSAVI as estimators of green biomass and coverage in a semi-arid rangeland. *Ecological Indicators*, 94(1), 16-21.
doi:<https://doi.org/10.1016/j.ecolind.2018.06.029>
- Gao, Y., Skutsch, M., Paneque-Gálvez, J., & Ghilardi, A. (2020). Remote sensing of forest degradation: a review. *Environmental Research Letters*, 15(10), 103001. doi:10.1088/1748-9326/abaad7
- Gitelson, A., Kaufman, Y., & Merzlyak, M. (1996). Use of a green channel in remote sensing of global vegetation from EOS - MODIS. *Remote Sensing of Environment*, 58(3), 289-298. doi:[https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

- Godingo, S., Guiomar, N., & Gil, A. (2018). Estimating tree canopy cover percentage in a mediterranean silvopastoral systems using Sentinel -2A imagery and the stochastic gradient boosting algorithm. *International Journal of Remote Sensing*, 39(14), 4640-4662. doi:<https://doi.org/10.1080/01431161.2017.1399480>
- Huete, A. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. doi:[https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- IGP. (2020). *Levantamiento tipográfico mediante fotogrametría aérea con dron y mediciones GPS de Alto Laran y Río Chico*, ICA. Lima.
- Jordan, C. (1969). Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, 50(4), 663-666. doi:<https://doi.org/10.2307/1936256>
- Matricardi, E., Skole, D., Pedlowski, M., Chomentowski, W., & Fernandes, L. (2010). Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. *Remote Sensing of Environment*, 1117-1129. doi:<https://doi.org/10.1016/j.rse.2010.01.001>
- MINAM. (2021). *Línea de base de los bosques secos de la costa norte del Perú al 2018*. Lima. Obtenido de <https://cdn.www.gob.pe/uploads/document/file/3249344/Apuntes-del-bosque-4.pdf.pdf>
- Ministerio de Transporte y comunicaciones. (2015). *Norma Técnica Complementaria NTC 001-2015 Requisitos para las operaciones de sistemas de aeronaves pilotadas a distancia*. Obtenido de https://cdn.www.gob.pe/uploads/document/file/390602/NTC__RPAS__texto_.pdf?v=1571265754
- Ministerio del Ambiente. (2015). *Guía de inventario de la flora y vegetación*. Lima: Ministerio del Ambiente . Dirección General de Evaluación, Valoración y Financiamiento dl Patrimonio Natural.
- NASA ARSET. (30 de 12 de 2024). *Earth Science Applied Sciences*. Obtenido de Fundamentos de la teledetección (Percepción Remota):

https://appliedsciences.nasa.gov/sites/default/files/2023-02/Fundamentals_of_RS_Span.pdf

- Nasiri, V., Darvishsefat, A. A., Arefi, H., Griess, V. C., Sadeghi, S. M., & Borz, S. A. (2022). Modeling Forest Canopy Cover: A Synergistic Use of Sentinel-2, Aerial Photogrammetry Data, and Machine Learning. *Remote Sensing*, *14*, 1453. doi:<https://doi.org/10.3390/rs14061453>
- 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. doi:<https://doi.org/10.3390/rs12152411>
- Qi, J. C., Huete, A., Kerr, Y., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, *48*(2), 119-126. doi:[https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rondeux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, *55*(2), 96-107. doi:[https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Roque Quiroz, R. (2022). Tendencia del NDVI en el Área de Conservación Regional Angostura Faical de Tumbes, Perú, 1999 - 2019. *Manglar*, 233-237. doi:<http://orcid.org/0000-0003-3399-1325>
- Roujean, J., & Breon, F. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, *51*(3), 375-384. doi:[https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J., Hass, R., Schell, J., & Deering, D. (1974). Monitoring vegetation systems in the great plains with ERTS. *NASA Spex.Publ*, *351*(1), 309.
- Santamaria, J., & Sanz, T. (2011). *Fundamentos de fotogrametria*. Universidad de la rioja.
- Scanlon, T., Albertson, J., Caylor, K., & Williams, C. (2002). Determining land surface fractional cover from NDVI and rainfall time series for a savana ecosystem. *Remote Sensing of Environment*, *82*(2-3), 376-388. doi:[https://doi.org/10.1016/S0034-4257\(02\)00054-8](https://doi.org/10.1016/S0034-4257(02)00054-8)

- Sobrino, J. (2001). *Teledetección*. (J. A. Sobrino Rodriguez, Ed.) Universidad de València Servicio de Publicaciones.
- Tucker, C. (1980). A spectral method for determining the percentage of green herbage material in clipped samples. *Remote Sensing of Environment*, 9(2), 175-181. doi:[https://doi.org/10.1016/0034-4257\(80\)90007-3](https://doi.org/10.1016/0034-4257(80)90007-3)
- Vargas Sabadías, A. (1995). *Estadística descriptiva e inferencial*. (U. d.-L. Mancha, Ed.) España.
- Vatandaşlar, C., & Yavuz, M. (2017). Modeling cover management factor of RUSLE using very high-resolution satellite imagery in a semiarid watershed. *Environmental Earth Sciences*, 76(65), 1 - 21. doi:<https://link.springer.com/article/10.1007/s12665-017-6388-0>
- Vigabriel Navarro, L., Osorio Leyton, J., Quezada Lambertin, C., & Benavides Lopez, J. (2024). Estimación de la biomasa del cultivo de cebada (*Hordeum vulgare* L.) mediante teledetección de imágenes multiespectrales. *Revista de Investigación e Innovación Agropecuaria y de Recursos Naturales*, 11(2), 18-29. doi:<https://doi.org/10.53287/iguo9951ru99j>
- Vizzari, M. (2022). PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. *Remote Sensing*, 14(11), 2628. doi:<https://doi.org/10.3390/rs14112628>
- Wang, N., Guo, Y., Wei, X., Zhou, M., Wong, H., & Bai, Y. (2022). UAV - based remote sensing using visible and multiespectral indices for the estimation of vegetation cover in an oasis of desert. *Ecological Indicators*, 141, 109155. doi:<https://doi.org/10.1016/j.ecolind.2022.109155>
- Xie, L., Meng, X., Zhao, X., Fu, L., Sharma, R., & Sun, H. (2022). Estimating Fractional Vegetation Cover Changes in Desert Regions Using RGB Data. *Remote Sensing*, 14(15), 3833. doi:<https://doi.org/10.3390/rs14153833>
- Xu, Z., Li, Y., Hao, Z., Lin, L., Hu, X., Zhou, X., . . . Li, Z. (2023). A comparative study on the applicability and effectiveness of NSVI and NDVI for estimating fractional vegetation cover based on multi-source remote sensing image. *Geocarto International*, 38(1), 2184501. doi:<https://doi.org/10.1080/10106049.2023.2184501>

Zhang, K., Zhang, Q., & Singh, V. (2024). Temporal Dynamics of Fractional Vegetation Cover in the Yellow Rivers Basin : A Comprehensive Analysis. *Remote Sensing*, 16(16), 2991. doi:<https://doi.org/10.3390/rs16162991>

Zheng, J.-J., Hao, Y.-Y., Wang, Y.-C., Zhou, S.-Q., Wu, W.-B., Yuan, Q., . . . Zhao, B. (2022). Coastal Wetland Vegetation Classification Using Pixel-Based, Object-Based and Deep Learning Methods Based on RGB-UAV. *Land*, 11(11), 2039. doi:<https://doi.org/10.3390/land11112039>

-

VIII. ANEXOS

Anexo 1. Parámetros de procesamiento de la parcela 1

Parámetros de procesamiento

Generales

Cámaras	995
Cámaras orientadas	995
Sistema de coordenadas	WGS 84 (EPSG::4326)
Ángulo de rotación	Guiñada, cabeceo, alabeo

Nube de puntos

Puntos	1,086,810 de 1,132,393
RMS error de reproyección	0.203169 (0.455998 pix)
Error de reproyección máximo	0.609877 (16.6779 pix)
Tamaño promedio de puntos característicos	2.07001 pix
Colores de puntos	1 banda, uint16
Puntos claves	No
Multiplicidad media de puntos de paso	3.8788

Parámetros de orientación

Precisión	Máxima
Pre-selección genérica	Sí
Pre-selección de referencia	Sí
Puntos claves por foto	40,000
Puntos de enlace por foto	4,000
Adaptativo ajuste del modelo de cámara	Sí
Tiempo búsqueda de puntos homólogos	2 minutos 32 segundos
Tiempo de orientación	7 minutos 45 segundos

Mapas de profundidad

Número	199
--------	-----

Parámetros de reconstrucción

Calidad	Extra alta
Nivel de filtrado	Agresivo
Duración del procesamiento	8 minutos 19 segundos

Nube de puntos densa

Puntos	98,345,887
Colores de puntos	5 bandas, uint16

Parámetros de reconstrucción

Calidad	Extra alta
Filtrado de profundidad	Agresivo
Tiempo de generación de mapas de profundidad	8 minutos 19 segundos
Tiempo de generación de nube de puntos densa	7 minutos 1 segundo

Modelo

Caras	19,517,277
Vértices	9,765,446
Colores de vértices	5 bandas, uint16
Textura	4,096 x 4,096, 6 bandas, uint16

Parámetros de reconstrucción

Tipo de superficie	Bajorrelieve / terreno
Datos fuente	Densa
Interpolación	Habilitada
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Número de caras	19,669,170
Duración del procesamiento	3 minutos 55 segundos

Parámetros de texturizado

Generales

Modo de mapeado	Genérico
Modo de mezcla	Mosaico
Tamaño de textura	4,096 x 4,096
Realizar el relleno de agujeros	Sí
Habilitar el filtro de efecto fantasma	Sí
Tiempo de mapeado en UV	3 minutos 8 segundos
Tiempo de mezcla	16 minutos 18 segundos

Modelo de teselas

Textura	5 bandas, uint16
---------	------------------

Parámetros de reconstrucción

Datos fuente	Malla
Tamaño de tesela	256
Número de caras	Alta
Habilitar el filtro de efecto fantasma	No
Duración del procesamiento	27 minutos 8 segundos

Modelo digital de elevaciones

Tamaño	12,544 x 13,132
Sistema de coordenadas	WGS 84 (EPSG::4326)

Parámetros de reconstrucción

Datos fuente	3
Interpolación	Habilitada
Duración del procesamiento	1 minuto 12 segundos

Ortomosaico

Tamaño	8,265 x 8,016
Sistema de coordenadas	WGS 84 (EPSG::4326)
Colores	5 bandas, uint16

Parámetros de reconstrucción

Modo de mezcla	Mosaico
Superficie	Modelo digital de elevaciones
Realizar el relleno de agujeros	Sí
Duración del procesamiento	1 minuto 22 segundos

Software

Versión	1.5.1 build 7618
Plataforma	Windows 64

Parámetros de procesamiento

Generales

Cámaras	995
Cámaras orientadas	995
Sistema de coordenadas	WGS 84 (EPSG::4326)
Ángulo de rotación	Guiñada, cabeceo, alabeo

Nube de puntos

Puntos	848,992 de 892,997
RMS error de reproyección	0.192153 (0.51203 pix)
Error de reproyección máximo	0.577557 (20.2199 pix)
Tamaño promedio de puntos característicos	2.3929 pix
Colores de puntos	1 banda, uint16
Puntos claves	No
Multiplicidad media de puntos de paso	4.97688

Parámetros de orientación

Precisión	Máxima
Pre-selección genérica	Sí
Pre-selección de referencia	Sí
Puntos claves por foto	40,000
Puntos de enlace por foto	4,000
Adaptativo ajuste del modelo de cámara	Sí
Tiempo búsqueda de puntos homólogos	2 minutos 49 segundos
Tiempo de orientación	5 minutos 58 segundos

Mapas de profundidad

Número	199
--------	-----

Parámetros de reconstrucción

Calidad	Extra alta
Nivel de filtrado	Agresivo
Duración del procesamiento	11 minutos 22 segundos

Nube de puntos densa

Puntos	75,492,378
Colores de puntos	5 bandas, uint16

Parámetros de reconstrucción

Calidad	Extra alta
Filtrado de profundidad	Agresivo
Tiempo de generación de mapas de profundidad	11 minutos 22 segundos
Tiempo de generación de nube de puntos densa	9 minutos 4 segundos

Modelo

Caras	14,971,472
Vértices	7,491,286
Colores de vértices	5 bandas, uint16
Textura	4,096 x 4,096, 6 bandas, uint16

Parámetros de reconstrucción

Tipo de superficie	Bajorrelieve / terreno
Datos fuente	Densa
Interpolación	Habilitada
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Número de caras	15,098,475
Duración del procesamiento	3 minutos 19 segundos

Parámetros de texturizado

Generales	
Modo de mapeado	Genérico
Modo de mezcla	Mosaico
Tamaño de textura	4,096 x 4,096
Realizar el relleno de agujeros	Sí
Habilitar el filtro de efecto fantasma	Sí
Tiempo de mapeado en UV	2 minutos 12 segundos
Tiempo de mezcla	13 minutos 30 segundos
Modelo de teselas	
Textura	5 bandas, uint16
Parámetros de reconstrucción	
Datos fuente	Malla
Tamaño de tesela	256
Número de caras	Alta
Habilitar el filtro de efecto fantasma	No
Duración del procesamiento	18 minutos 12 segundos
Modelo digital de elevaciones	
Tamaño	11,396 x 11,546
Sistema de coordenadas	WGS 84 (EPSG::4326)
Parámetros de reconstrucción	
Datos fuente	3
Interpolación	Habilitada
Duración del procesamiento	1 minuto 2 segundos
Ortomosaico	
Tamaño	7,399 x 6,907
Sistema de coordenadas	WGS 84 (EPSG::4326)
Colores	5 bandas, uint16
Parámetros de reconstrucción	
Modo de mezcla	Mosaico
Superficie	Modelo digital de elevaciones
Realizar el relleno de agujeros	Sí
Duración del procesamiento	1 minuto 15 segundos
Software	
Versión	1.5.1 build 7618
Plataforma	Windows 64

Parámetros de procesamiento

Generales	
Cámaras	1030
Cámaras orientadas	1030
Sistema de coordenadas	WGS 84 (EPSG::4326)
Ángulo de rotación	Guiñada, cabeceo, alabeo
Nube de puntos	
Puntos	807,255 de 857,548
RMS error de reproyección	0.202193 (0.467012 pix)
Error de reproyección máximo	0.607408 (17.6939 pix)
Tamaño promedio de puntos característicos	2.18533 pix
Colores de puntos	1 banda, uint16
Puntos claves	No
Multiplicidad media de puntos de paso	5.78026
Parámetros de orientación	
Precisión	Máxima
Pre-selección genérica	Sí
Pre-selección de referencia	Sí
Puntos claves por foto	40,000
Puntos de enlace por foto	4,000
Adaptativo ajuste del modelo de cámara	Sí
Tiempo búsqueda de puntos homólogos	3 minutos 16 segundos
Tiempo de orientación	5 minutos 21 segundos
Mapas de profundidad	
Número	206
Parámetros de reconstrucción	
Calidad	Extra alta
Nivel de filtrado	Agresivo
Duración del procesamiento	10 minutos 14 segundos
Nube de puntos densa	
Puntos	94,904,398
Colores de puntos	5 bandas, uint16
Parámetros de reconstrucción	
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Tiempo de generación de mapas de profundidad	10 minutos 14 segundos
Tiempo de generación de nube de puntos densa	7 minutos 27 segundos
Modelo	
Caras	18,798,769
Vértices	9,406,796
Colores de vértices	5 bandas, uint16
Textura	4,096 x 4,096, 6 bandas, uint16
Parámetros de reconstrucción	
Tipo de superficie	Bajorrelieve / terreno
Datos fuente	Densa
Interpolación	Habilitada
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Número de caras	18,980,879
Duración del procesamiento	4 minutos 18 segundos
Parámetros de texturizado	

Generales

Modo de mapeado	Genérico
Modo de mezcla	Mosaico
Tamaño de textura	4,096 x 4,096
Realizar el relleno de agujeros	Sí
Habilitar el filtro de efecto fantasma	Sí
Tiempo de mapeado en UV	2 minutos 41 segundos
Tiempo de mezcla	14 minutos 28 segundos

Modelo de teselas

Textura	5 bandas, uint16
---------	------------------

Parámetros de reconstrucción

Datos fuente	Malla
Tamaño de tesela	256
Número de caras	Alta
Habilitar el filtro de efecto fantasma	No
Duración del procesamiento	28 minutos 14 segundos

Modelo digital de elevaciones

Tamaño	12,195 x 12,453
Sistema de coordenadas	WGS 84 (EPSG::4326)

Parámetros de reconstrucción

Datos fuente	3
Interpolación	Habilitada
Duración del procesamiento	1 minuto 28 segundos

Ortomosaico

Tamaño	8,930 x 8,627
Sistema de coordenadas	WGS 84 (EPSG::4326)
Colores	5 bandas, uint16

Parámetros de reconstrucción

Modo de mezcla	Mosaico
Superficie	Modelo digital de elevaciones
Realizar el relleno de agujeros	Sí
Duración del procesamiento	1 minuto 50 segundos

Software

Versión	1.5.1 build 7618
Plataforma	Windows 64

Parámetros de procesamiento

Generales

Cámaras	985
Cámaras orientadas	985
Sistema de coordenadas	WGS 84 (EPSG::4326)
Ángulo de rotación	Guiñada, cabeceo, alabeo

Nube de puntos

Puntos	911,684 de 955,538
RMS error de reproyección	0.204692 (0.467069 pix)
Error de reproyección máximo	0.614743 (16.2531 pix)
Tamaño promedio de puntos característicos	2.11988 pix
Colores de puntos	1 banda, uint16
Puntos claves	No
Multiplicidad media de puntos de paso	4.60509

Parámetros de orientación

Precisión	Máxima
Pre-selección genérica	Sí
Pre-selección de referencia	Sí
Puntos claves por foto	40,000
Puntos de enlace por foto	4,000
Adaptativo ajuste del modelo de cámara	Sí
Tiempo búsqueda de puntos homólogos	2 minutos 26 segundos
Tiempo de orientación	4 minutos 56 segundos

Mapas de profundidad

Número	197
--------	-----

Parámetros de reconstrucción

Calidad	Extra alta
Nivel de filtrado	Agresivo
Duración del procesamiento	10 minutos 25 segundos

Nube de puntos densa

Puntos	82,553,165
Colores de puntos	5 bandas, uint16

Parámetros de reconstrucción

Calidad	Extra alta
Filtrado de profundidad	Agresivo
Tiempo de generación de mapas de profundidad	10 minutos 25 segundos
Tiempo de generación de nube de puntos densa	7 minutos 50 segundos

Modelo

Caras	16,365,657
Vértices	8,188,901
Colores de vértices	5 bandas, uint16
Textura	4,096 x 4,096, 6 bandas, uint16

Parámetros de reconstrucción

Tipo de superficie	Bajorrelieve / terreno
Datos fuente	Densa
Interpolación	Habilitada
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Número de caras	16,510,632
Duración del procesamiento	3 minutos 54 segundos

Parámetros de texturizado

Generales

Modo de mapeado	Genérico
Modo de mezcla	Mosaico
Tamaño de textura	4,096 x 4,096
Realizar el relleno de agujeros	Sí
Habilitar el filtro de efecto fantasma	Sí
Tiempo de mapeado en UV	2 minutos 21 segundos
Tiempo de mezcla	13 minutos 29 segundos

Modelo de teselas

Textura 5 bandas, uint16

Parámetros de reconstrucción

Datos fuente	Malla
Tamaño de tesela	256
Número de caras	Alta
Habilitar el filtro de efecto fantasma	No
Duración del procesamiento	22 minutos 58 segundos

Modelo digital de elevaciones

Tamaño 12,682 x 12,946
Sistema de coordenadas WGS 84 (EPSG::4326)

Parámetros de reconstrucción

Datos fuente	3
Interpolación	Habilitada
Duración del procesamiento	1 minuto 10 segundos

Ortomosaico

Tamaño 7,835 x 7,473
Sistema de coordenadas WGS 84 (EPSG::4326)
Colores 5 bandas, uint16

Parámetros de reconstrucción

Modo de mezcla	Mosaico
Superficie	Modelo digital de elevaciones
Realizar el relleno de agujeros	Sí
Duración del procesamiento	1 minuto 22 segundos

Software

Versión 1.5.1 build 7618
Plataforma Windows 64

Parámetros de procesamiento

Generales

Cámaras	985
Cámaras orientadas	985
Sistema de coordenadas	WGS 84 (EPSG::4326)
Ángulo de rotación	Guiñada, cabeceo, alabeo

Nube de puntos

Puntos	700,876 de 745,249
RMS error de reproyección	0.206947 (0.436066 pix)
Error de reproyección máximo	0.621883 (13.4916 pix)
Tamaño promedio de puntos característicos	1.9939 pix
Colores de puntos	1 banda, uint16
Puntos claves	No
Multiplicidad media de puntos de paso	6.47998

Parámetros de orientación

Precisión	Máxima
Pre-selección genérica	Sí
Pre-selección de referencia	Sí
Puntos claves por foto	40,000
Puntos de enlace por foto	4,000
Adaptativo ajuste del modelo de cámara	Sí
Tiempo búsqueda de puntos homólogos	2 minutos 45 segundos
Tiempo de orientación	7 minutos 4 segundos

Mapas de profundidad

Número	197
--------	-----

Parámetros de reconstrucción

Calidad	Extra alta
Nivel de filtrado	Agresivo
Duración del procesamiento	14 minutos 30 segundos

Nube de puntos densa

Puntos	67,059,705
Colores de puntos	5 bandas, uint16

Parámetros de reconstrucción

Calidad	Extra alta
Filtrado de profundidad	Agresivo
Tiempo de generación de mapas de profundidad	14 minutos 30 segundos
Tiempo de generación de nube de puntos densa	9 minutos 47 segundos

Modelo

Caras	13,298,186
Vértices	6,654,636
Colores de vértices	5 bandas, uint16
Textura	4,096 x 4,096, 6 bandas, uint16

Parámetros de reconstrucción

Tipo de superficie	Bajorrelieve / terreno
Datos fuente	Densa
Interpolación	Habilitada
Calidad	Extra alta
Filtrado de profundidad	Agresivo
Número de caras	13,411,941
Duración del procesamiento	2 minutos 34 segundos


Parámetros de texturizado

Generales	
Modo de mapeado	Genérico
Modo de mezcla	Mosaico
Tamaño de textura	4,096 x 4,096
Realizar el relleno de agujeros	Sí
Habilitar el filtro de efecto fantasma	Sí
Tiempo de mapeado en UV	2 minutos 18 segundos
Tiempo de mezcla	12 minutos 23 segundos
Modelo de teselas	
Textura	5 bandas, uint16
Parámetros de reconstrucción	
Datos fuente	Malla
Tamaño de tesela	256
Número de caras	Alta
Habilitar el filtro de efecto fantasma	No
Duración del procesamiento	18 minutos 32 segundos
Modelo digital de elevaciones	
Tamaño	11,047 x 10,928
Sistema de coordenadas	WGS 84 (EPSG::4326)
Parámetros de reconstrucción	
Datos fuente	3
Interpolación	Habilitada
Duración del procesamiento	59 segundos
Ortomosaico	
Tamaño	7,583 x 6,996
Sistema de coordenadas	WGS 84 (EPSG::4326)
Colores	5 bandas, uint16
Parámetros de reconstrucción	
Modo de mezcla	Mosaico
Superficie	Modelo digital de elevaciones
Realizar el relleno de agujeros	Sí
Duración del procesamiento	1 minuto 23 segundos
Software	
Versión	1.5.1 build 7618
Plataforma	Windows 64


Anexo 6. fotografía panorámica del área de estudio




Anexo 7. Mapa de la fracción de cobertura vegetal del año 1986 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes




Anexo 8. Mapa de la fracción de cobertura vegetal del año 1999 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes



Anexo 9. Mapa de la fracción de cobertura vegetal del año 2014 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes



Anexo 10. Mapa de la fracción de cobertura vegetal del año 2024 en el taller de enseñanza e investigación forestal y fauna silvestre Universidad Nacional de Tumbes



Anexo 11. Precipitaciones pluviales histórica de la Estación Meteorológica "Puerto Pizarro"

Precipitaciones pluviales (mm/año) Estación Meteorológica "Puerto Pizarro"													
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Setiembre	Octubre	Noviembre	Diciembre	Total
1985	6.9	1.7	23.3	0	7	0	1.94	2.2	0.03	1.62	0	1.1	45.79
1986	47.9	5.7	0.6	67.5	2	0	0	0	0	0	0	1	124.7
1987	44.3	254	260.5	52.5	2	0	0	0.61	0	0.8	0	0	614.71
1988	15.5	34	1.7	21	0	0	0.7	0	0.7	0	1.7	0	75.3
1989	78	228.5	152.5	13.5	0	0	0	0	0	0	0	0	472.5
1990	3	75	9.3	4	0	0	0	0	0	6.7	1.8	0.9	100.7
1991	2.3	46	74		38	0	0	0	0	0	1	9	170.3
1992						0	0	0	1	1.3	2.4	1.5	6.2
1993	7.5	111.6	106	32.6	22.6	0	0	0	0	3	0.4	7.2	290.9
1994	67.3	46.5	45.5	15.4	4.8	1.4	4	0.7	1.2	0	0.6	4	191.4
1995		88.8	47.4	0	1.4	0	0.5	0	0	1.2	7.9	8.4	155.6
1996	15	52.7	15.1	18.7	0.4	0	0	0	0	2.1	0.5	0	104.5
1997	2.1	32.4	127.5	44.4	24.7	3.7	12.4	0.5	3.7	4.3	149.3	649.7	1054.7
1998	388.5	932.9	503.4	426.4	165.6	0.5	0.6	0	0.2	5	0	10.5	2433.6
1999	4.9	110.2	202.2	59.8	13.1	2.9	1.2	0	1.1	2.6	1.5	2.2	401.7
2000	4.3	38.4	43.5	63.8	13.7	3.5	0	1.2	0	0	0	5.8	174.2
2001	37.8	53.1	224.1	57.9	1.3	0.2	0	0	0.3	0	5.4	3.2	383.3
2002	1.1	199.3	315.1	130	0	0	0	0	0	1.6	0	3.7	650.8
2003	17.3	41.2	15.7	11.9	4.1	0.4	0.8	0	0	0	1	39.4	131.8
2004	19.5	17.4	43	47.9	9.2	0.3	0	0	2.2	7	0	1.1	147.6
2005	3.4	5.7	44.9	65.5	0	0.8	0	0	0	1.6	0.5	9.9	132.3
2006	37.9	226.6	37.5	5.2	0	1	1.7	0.3	0	0	3.4	1.6	315.2
2007	67.2	8	56.1	3.2	5	0	0	1	0	1.8	2.5	2.1	146.9
2008	135.2	265.6	109.6	22.7	0	0	0	0	0	0.7	0	0	533.8
2009	130.8	97.3	17.8	19.9	5.6	0	0	0	0	0	3.1	1.2	275.7
2010	12	185.9		88	0	0	0	0	0.2	0	2.1		288.2

2011	27.6	40.6	4.3	32.3	2.6	0	2	0	0	0	0	1.1	110.5
2012	53.6	110.6	83.4	42.1	0	0.2	0.5	0	0	0	0	2.7	293.1
2013	16.8	35.1	82.8	78.6	4.2	0	0.5	0	0	4	0	0	222
2014	21	18.7	10	2	22.8	0	0	0	0	5	0	10.8	90.3
2015	12.5	32.3	231.4		35.61	0	0	0	0	4.1			315.91
2016	61.4	265	279.5	64.4	0	18.8	1	0.6	0	0	0	12.7	703.4
2017	253.8	223.8	254.6	49.8	34	0	0.2	0	0	0.8	0	0	817
2018	49.79	121.33	21.6	0	51.8	0	0	0	0	0.8	0.5	34.6	280.42
2019	24.1	146.6	18.4	33.6	0	0	0	0.6	0	0	1.2	22.8	247.3
2020	18.8	150.4	113.4	0	0	0	0	0	0.5	0	0.5	12.5	296.1
2023	5.2	70.6	0	0	0	0	0	0	0	0	0	0	75.8