



INFORME FINAL DEL ESTUDIO DE LA EVALUACIÓN DE SEQUÍAS AGRÍCOLAS UTILIZANDO INFORMACIÓN SATELITAL EN LA PROVINCIA DE MORROPÓN, DEPARTAMENTO DE PIURA

Resumen

En la región Piura los impactos de la seguía han ocasionado pérdidas considerables en las provincias de Morropón, Ayabaca y Huancabamba incluidas las provincias ubicadas en la Costa como Piura, Sullana, Sechura, Paita y Talara en los años 2003, 2004 y 2005, generando una pérdida de miles de hectáreas en cultivos instalados o dejadas de instalar; pérdida de hatos de ganado debido a la escasez de pastos propiciando la migración del poblador rural a las ciudades urbano marginales, según los reportes de la Dirección Regional de Agricultura, entre los meses de Enero y Febrero del 2004 las pérdidas a causa de las seguías afectaron 9 028 Ha de Cultivos instalados, valorizados en S/. 7 273 262.63.

Por otro lado, entre octubre 2004 a febrero 2005, los efectos de heladas y seguía, afectaron a los cultivos de pan llevar, pastos y ganadería, por un valor de S/. 46 305 725.75 (PRPAD-Región Piura-2005).

Además, según el reporte histórico de producción agrícola publicado por el MINAGRI, durante el año 2004 la región de Piura, fue afectada por los efectos de la sequía, ocasionado una reducción en la producción de los campos de cultivo.

En la actualidad, existen diversos métodos de monitoreo e identificación para zonas afectadas por fenómenos naturales, entre ellos, la ausencia de precipitaciones en un determinado período que afectan a diversos sectores socioeconómicos; como la agricultura, ganadería, turismo, entre otros.

Dada la necesidad de contar con información disponible sobre los impactos de las sequías agrícolas, que generan grandes pérdidas en diferentes sectores económicos y sociales sobre el territorio peruano y



sobre grandes áreas, es difícil monitorearlo con un sistema convencional; por ello se propone el estudio y análisis de zonas afectadas por seguías agrícolas o agronómicas con uso de información satelital e información complementaria de diversas instituciones a fines.

Estudios previos, muestran que los sectores vulnerables a este fenómeno climático-representan un 42.1% de la población total del país se encuentra expuesta al peligro de Seguías (PREVAED, 2019).

1. Introducción

Las seguías constituyen una adversidad climática recurrente en vastas regiones del mundo y su duración e intensidad son causas de importantes pérdidas económicas y disrupciones en las actividades de las comunidades rurales y urbanas (Downing, Baker, 2000). La principal causa de una seguía es la ausencia de precipitaciones durante un tiempo prolongado (Wilhite y Glantz, 1985). Por otro lado, la ocurrencia de un período seco estacional muy acotado en zonas de abundantes precipitaciones es conocida como la canícula. La canícula es definida por algunos autores como la reducción notable de las precipitaciones, asociada a varios días secos consecutivos, que aparecen con mayor frecuencia en los últimos diez días de julio y los primeros diez días de agosto.Esta ausencia de precipitación es mucho más acotado en el tiempo y en el espacio territorial y si bien puede causar daños a la producción agrícola no tiene la misma dimensión del impacto que tienen las seguías (Garcia Guirola et al., 2013). El área de afectación comprende a países de Centro América y el Caribe. Entre los factores que influyen en los daños ocasionados por las seguías son, la distribución espacial e intensidad de las precipitaciones, así como la cantidad de agua almacenada en el suelo y en los reservorios de provisión en relación a la demanda y al uso del agua por parte de los cultivos y la población (Milan-Gocic, 2014). Se considera factible, que en un futuro cercano las seguías se intensifiquen a raíz de los cambios climáticos evidenciados en los últimos años. Además, se prevé que aumentará la extensión de



territorios afectados por seguías, generando un mayor impacto en regiones agrícolas (IPCC, 2007).

La deficiencia de precipitaciones por debajo del valor normal ocasiona una escasez de agua que afecta el desarrollo de actividades agroproductivas, (Ravelo et al., 2003) industriales y sociales, afectando a todos los sectores de la población (Ravelo, 1980). Más allá de los costos productivos y monetarios, los impactos de una seguía perjudica a toda la sociedad y afectan negativamente a todos los componentes de los ecosistemas, produciendo deseguilibrios ecológicos con consecuencias difíciles de revertir (Ravelo, 2000), que conducen a una aceleración de los procesos de desertificación (Planchuelo & Ravelo, 2003). Es por esas razones que, con frecuencia, las instituciones públicas y privadas deben tomar medidas que ayuden a mitigar los efectos de este fenómeno meteorológico (Ravelo et al., 2008).

La evaluación de la seguía se puede analizar utilizando imágenes satelitales. La teledetección es uno de los métodos de evaluación rápida y eficaz de la seguía que utiliza una amplia distribución de índices espectrales (matemática de bandas) en determinados periodos. Los índices que se pueden aplicar son: Índice de vegetación diferenciada normalizada (NDVI) (Zuzulova & Vido, 2018) y Temperatura de la superficie terrestre (LST) (Karnieli et al., 2009). Los índices compuestos de NDVI y LST que también se pueden aplicar son:

Índice de condición de la vegetación (VCI) (Adede etal., 2019), Índice de salud de la vegetación (VHI) (Kogan, 1995) e Índice de condición de temperatura de la vegetación (VTCI) (Kham et al., 2018).

2. Antecedentes

2.1 En el año 1998, Chuvieco, S.E. realizó el estudio "El factor temporal en teledetección: evolución fenológica y análisis de cambios", el objetivo del estudio fue obtener información multitemporal a partir de imágenes de satélites, con especial énfasis en las aplicaciones





ambientales. Se distinguen dos grupos de técnicas: aquéllas que se aplican a las imágenes originales (o variables continúas derivadas de ellas) y a las que se centran en variables cualitativas (ya clasificadas). En ambos casos, resulta crucial que los datos sean comparables radiométrica y geométricamente.

Dentro del análisis temporal se determina perfiles de estaciones en las cubiertas vegetales de interés, la interpretación se realiza sobre las distintas fechas de modo simultáneo. Por ejemplo, si se pretende mejorar la clasificación de un determinado cultivo, se acude a imágenes de momentos clave dentro de su ciclo fenológico, que permitan separarlo con nitidez de otros cultivos espectralmente similares. Asimismo, se realizó una serie de imágenes de índices de vegetación correspondientes a la primavera y el verano de 1994 sobre la comunidad autónoma de Andalucía, en donde el NDVI: indica el valor del índice de vegetación para el período i, y NDVI_{min} y NDVI_{max} los valores mínimos y máximos, respectivamente de los índices en cada píxel para la serie de imágenes analizadas. Este índice se ha comprobado de gran interés en la estimación del peligro de incendios o condiciones de sequía.

3. Identificación y Formulación del Problema

Un problema que afronta el Perú es la gran demanda alimenticia existente; problema que se ve agravado por la escasez de suelos con aptitud agrícola, heterogeneidad fisiográfica, falta de tecnología y el cambio climático que afecta el crecimiento y el desarrollo de los cultivos.

Entre los elementos del clima vinculados con los riesgos climáticos, se encuentran las sequías. Las sequías son una parte normal del clima y pueden darse en todos los regímenes climáticos del mundo, incluso en desiertos y bosques lluviosos. Son uno de los peligros naturales más costosos año tras año: sus efectos son considerables y generalizados, al perjudicar a muchos sectores económicos y personas en cada ocasión. El efecto de las sequías suele ser mayor que el de otros peligros, generalmente se circunscribe a llanuras inundables, regiones costeras, la



trayectoria de la tormenta o las zonas de fallas. Tal vez no haya otro peligro que se preste tanto a ser objeto de seguimiento, toda vez que su lenta aparición hace factible que se observen los cambios en la precipitación, la temperatura y la situación general de las reservas de agua superficial y de agua subterránea en una región.

DIRECCIÓN DE

APLICACIONES Y

GEOMÁTICA - DIAPG

Durante el 2013 hasta los inicios del 2017 se registró un total de 1,532 emergencias asociadas a las sequías, según el INDECI, a través del SINPAD se tuvo, 75,305 damnificados, 752,291 hectáreas de cultivos destruidos y más de 1'895,734 animales fallecidos. Siendo el año 2016 que registró el mayor número de emergencias (848) y hectáreas de cultivos destruidos (698,831), además del mayor número de animales perdidos por el fenómeno (274,981)

Durante ese año, los departamentos con mayor registro de emergencias asociadas a las sequías fueron : Ayacucho (186), Apurímac (164), Huancavelica (136) y Junín (88). Por otro lado, los departamentos que presentaron mayor número de hectáreas afectadas son Ayacucho (671,326) y Cusco (13,097).

4. Justificación

La importancia de conocer el comportamiento temporal y espacial de las sequías, cumple un factor importante en el sector agrario, dado que son los primeros en sufrir grandes pérdidas económicas, la agricultura adquiere una especial relevancia en relación con la sequía. Y, por ende, se produce una sequía agrícola cuando no hay suficiente humedad en el suelo que permita el desarrollo normal de los cultivos en cualquiera de sus fases de crecimiento.

Además, el requerimiento de agua en los cultivos es diferente e incluso puede variar a lo largo del crecimiento de una misma planta.

Asimismo, se espera desarrollar metodologías que permitan identificar zonas afectadas por sequías , siendo el caso de estudio en la Provincia de Morropón-Piura con la finalidad de determinar su dimensión e intensidad

AGENCIA ESPACIAL

DEL PERÚ

CONIDA





en zonas vulnerables y contar con información actualizada en beneficio de las entidades, autoridades y la población.

5. Objetivos de la Investigación

5.1 Objetivo General

Validar una metodología para la identificación de áreas susceptibles al peligro de seguías agrícolas en base a información satelital y complementaria sobre la provincia de Morropón, departamento de Piura en el periodo 2002-2020.

5.2 Objetivos Específicos

- Elaborar mapas de seguías agrícolas, utilizando el índice de salud vegetal estimadas con imágenes satelitales adecuadas a las condiciones del territorio peruano para el periodo del 2002 al 2020 en Morropón-Piura.
- Elaborar mapas de peligros ante seguías meteorológicas, utilizando información histórica de estaciones meteorológicas e información de emergencias por desastres para el periodo 2002 al 2020 en Morropón-Piura.
- Reconocer los patrones entre las seguías agrícolas y las lluvias para el periodo 2002 al 2020 en Morropón-Piura.
- Generar un modelo autorregresivo del VHI para la localidad de Morropón-Piura.

6. Marco Legal

Como las políticas públicas están enmarcadas en un contexto normativo, es importante mencionar algunas referencias legales.

6.1 Constitución Política del Perú de 1993: Artículo 44°: "Son deberes primordiales del estado: garantizar la plena vigencia de los derechos humanos; proteger a la población de las amenazas contra su seguridad".





Lev Nº 29664 "Sistema Nacional de Gestión del Riesgo de 6.2 Desastres" (SINAGERD): Artículo 1.- Créase el Sistema Nacional de Gestión del Riesgo de Desastres como sistema interinstitucional, sinérgico, descentralizado, transversal y participativo, con la finalidad de identificar y reducir los riesgos asociados a peligros o minimizar sus efectos, así como evitar la generación de nuevos riesgos, y preparación y atención ante situaciones de desastre mediante el establecimiento de de política, componentes, principios, lineamientos procesos е instrumentos de la Gestión del Riesgo de Desastres.

6.3 Ley Nº 27867 "Ley Orgánica de los Gobiernos Regionales": Artículo 6°: "El desarrollo regional comprende la aplicación coherente y eficaz de las políticas e instrumentos de desarrollo económico social, poblacional, cultural y ambiental, a través de planes, programas y proyectos que permitan el crecimiento económico armonizado con la dinámica demográfica, el desarrollo social equitativo y la conservación de los recursos naturales y el ambiente en el territorio regional".

Decreto Supremo N° 036-2018-PCM "Plan Multisectorial Ante 6.4 Heladas y Friaje 2018": En determinadas épocas del año, varios departamentos de la sierra y selva del país enfrentan la presencia de bajas temperaturas, generando efectos negativos en la vida, salud y educación, así como en la actividad agrícola y ganadera, en las poblaciones que residen en dichas zonas y que además se encuentran en una situación de mayor vulnerabilidad, debido a su condición social (pobreza y pobreza extrema), su ciclo de vida (niños y niñas, personas adultas mayores), etc.; todo lo cual afecta su forma de vida y la economía local.

Decreto Supremo N° 034-2014-PCM "Plan Nacional de Gestión del 6.5 Riesgo de Desastre - PLANAGERD (2014-2021): Se orienta finalmente a lograr una sociedad segura y resiliente ante el riesgo de desastres; bajo este marco, establece el siguiente objetivo nacional: Reducir la vulnerabilidad de la población y sus medios de vida, ante el riesgo de





desastres.

DEL PERÚ

7. Metodología

Para la metodología del presente estudio se desarrollaron las siguientes

fases





Figura N°1: Flujo de procesos para desarrollo de la investigación



7.1 Revisión bibliográfica y/o búsqueda de fuentes

Para el desarrollo de la presente investigación, se recopiló información de trabajos existentes que sirvieron de antecedentes en el desarrollo de la metodología utilizada y también para la revisión del marco conceptual.

7.2. Datos utilizados

7.2.1. Imágenes satelitales

a. Moderate-Resolution Imaging Spectroradiometer (MODIS)

El experimento a largo plazo MODIS es parte del Sistema de Observación de la Tierra (EOS) que está integrado en la empresa interdisciplinaria de Ciencias de la Tierra de la NASA (ESE; NASA 2003a, 2003b, NASA 2007). Con la herencia de múltiples sensores, incluidos AVHRR, TM / ETM + y CZCS, MODIS enfrenta el desafío de satisfacer las necesidades atmosféricas, oceanográficas y terrestres.

Los diferentes campos científicos que compiten entre sí pueden parecer una carga a primera vista, tal vez evitando el valor agregado para la comunidad de usuarios. Por ejemplo, si bien una resolución espacial de 1 km es suficiente para los productos atmosféricos y oceánicos, muchas aplicaciones terrestres requieren una resolución espacial de al menos 500 metros e incluso se requiere un mayor detalle. Además, se requieren registros de longitudes de onda específicas para generar productos atmosféricos como la temperatura de las nubes, el contenido de ozono y la humedad troposférica.

Como tales, son de menor importancia para las aplicaciones terrestres. Sin embargo, un requisito fundamental de la comunidad terrestre es una corrección atmosférica completa y precisa, incluida la reducción de la dispersión y la corrección de aerosoles y ozono. La rama de ciencias atmosféricas proporciona los parámetros necesarios para ejecutar modelos de transferencia de radiación para una recuperación precisa de la reflectancia de la superficie. La identificación precisa de nubes de subpíxeles también es esencial para los estudios de la tierra. En total, después de siete años de funcionamiento, el experimento MODIS se considera una empresa exitosa y un trabajo conjunto entre diferentes comunidades científicas.

A. Conjuntos de datos terrestres de MODIS

La generación de productos de imágenes MODIS sigue un procedimiento bien definido con varios niveles. Las siguientes secciones se centrarán principalmente en los productos de MODIS land (MODLand) (Tabla 1; Justice et al. 1998, Justice et al. 2002a, King et al. 2004, Masuoka et al. 1998, Roy et al.2002a, Wolfe et al.1998). Los productos se proporcionan a la comunidad de usuarios en formato de datos jerárquicos (HDF; Masuoka et al. 1998). Cada producto se abrevia con MOD, MYD y MCD para indicar los productos Terra, Aqua o Terra / Aqua combinados, respectivamente. Sin embargo, MOD también se usa a menudo para especificar productos MODIS en general y se usará en este sentido a menos que se indique lo contrario. Una combinación de números y caracteres sigue al identificador de tres letras mayúsculas que indica los detalles del producto.

		Resolución	Resolución	
Parametros	Producto	espacial (m)	temporal (días)	Nivel
LST/emisividad	MOD11A2	1000	8	3
índice de vegetación	MOD13A1	250	16	3

Tabla N°1: Lista de productos MODLand (Traducido por : Caceres Andy)

Fuente: Colditz,2007

Para este estudio se consideró los parámetros de LST/emissivity y Vegetation index, cabe recalcar que estos productos están disponibles tanto para el sensor Terra y Aqua

MODIS Land Surface Temperature and Emissivity (MOD11)

De manera similar a la reflectancia de la superficie, la temperatura de la superficie terrestre es un parámetro clave para el producto de cobertura terrestre (MOD12) y la anomalía térmica y fuego (MOD14). Los productos LST son necesarios para varios estudios climáticos, hidrológicos, ecológicos y biogeoquímicos (Justice et al. 1998). Mientras que LST es la temperatura

medida (en Kelvin) en la parte superior de la superficie de la Tierra en el contacto con la atmósfera, la emisividad (sin unidades) es la relación entre el flujo radiante que sale de la superficie y un cuerpo negro a la misma temperatura (Jensen 2007). Si bien las bandas MIR MODIS (20, 21, 22 y 23) también son relevantes para aplicaciones terrestres como el mapeo de incendios, las bandas TIR (9, 31 y 32) se utilizan principalmente para el mapeo de emisividad y LST (Petitcolin y Vermote 2002).

Se utilizan dos algoritmos para la recuperación LST de píxeles no nublados, un enfoque de ventana dividida común para datos de 1 km (Becker y Li 1990, Wan y Dozier 1996) y un método día / noche recientemente desarrollado para productos de resolución espacial gruesa (Wan y Li 1997). Dependiendo de la cobertura terrestre derivada del producto MOD12, el algoritmo de ventana dividida calcula el LST a partir de la diferencia lineal de la temperatura de brillo entre las bandas 31 y 32. El algoritmo tiene en cuenta el ángulo de visión, el vapor de agua y la temperatura del límite inferior atmosférico. De manera similar, las emisividades de banda se estiman a partir de la clasificación IGBP del producto MOD12 y BRDF y modelado de emisividad (Snyder et al. 1998, Snyder y Wan 1998). El nuevo enfoque basado en la física, calcula las emisividades en bandas y las temperaturas diurnas y nocturnas de celdas de resolución espacial de 4,6 km y cuadrículas de modelado climático (CMG). El enfoque se basa en pares día / noche de bandas MODIS MIR y TIR. Este enfoque emplea tablas de consulta derivadas de MODTRAN para un procesamiento eficiente y también tiene en cuenta las incertidumbres atmosféricas como la temperatura del aire cerca de la superficie de día / noche y el vapor de agua (Wan y Li 1997, Wan et al. 2002, Wan et al. 2004). La validación de LST es difícil y se produjo en superficies homogéneas y diferentes tipos de cobertura durante varias campañas de campo. Reveló diferencias de menos de 1 K para temperaturas entre 263 K y 323 K (Wan et al. 2002, Wan et al. 2004).

Los productos MOD11 se proporcionan como gránulos de Nivel 2 y placas de Nivel 3 con períodos de composición diarios, de 8 días y mensuales. Además, el nivel 3 LST y la emisividad se obtienen a una resolución espacial de 1 km y 4,6 km y en CMG globales de 0,05°.

MODIS Vegetation Index Product (MOD13)

Desde los inicios de la teledetección terrestre, los índices de vegetación se han utilizado para caracterizar y conocer la dinámica de la superficie terrestre (Justice et al. 1985, Townshend and Justice 1986, Tucker 1979). El índice espectral del NDVI es estimado a partir de una diferencia normalizada entre el rojo y el infrarrojo cercano. Se conocen diversos índices de vegetación que consideran la vegetación escasa (SAVI; Huete 1988), las interferencias atmosféricas (ARVI; Kaufman y Tanre 1992) o la combinación de ambos (SARVI; Huete et al. 1994). Debido a las bandas visibles adicionales de MODIS, el NDVI se complementa con el EVI, un índice novedoso que también incorpora la reflectancia de la superficie azul y roja (Huete et al. 1997, Huete et al. 2002). La composición de los índices de vegetación es muy importante para el análisis de series de tiempo .Dependiendo del número de observaciones sin nubes, se aplican diferentes métodos de composición. La composición de BRDF (van Leeuwen et al. 1999) se aplica para más de cinco observaciones sin nubes por píxel, la composición de valor máximo de vista restringida (CV MVC; Huete et al. 2002) para uno a cinco píxeles buenos, índice de vegetación simple cálculo para una buena observación y el método MVC (Holben, 1986) si todas las observaciones tienen limitaciones. Se estima que las incertidumbres del índice de vegetación son inferiores al 2% para el rango dinámico (Miura et al. 2000). La comparación de los productos MOD13 para varios ecosistemas y períodos mostró una buena correspondencia con otros parámetros físicos y biofísicos, incluida la reflectancia superficial y el LAI. El MODIS NDVI mostró un rango dinámico mucho más alto en áreas con vegetación debido a un rango espectral más estrecho de las bandas roja y NIR en comparación con los instrumentos AVHRR (Huete et al. 2002). En comparación con NDVI, EVI muestra una mejor estabilidad, es menos susceptible a las perturbaciones atmosféricas y no se satura en regiones de alta biomasa.

Los datos MOD13 se proporcionan como compuestos de 16 días y mensuales y con resoluciones espaciales de 250 m.

b. New Astrosat Optical Modular Instrument (NAOMI)

NAOMI, instrumento óptico de carburo de silicio a bordo del satélite PerúSAT-1 (Astrobus). Es un satélite de observación de la tierra (Tabla N° 2) con capacidad de captar imágenes multiespectrales en el rango del espectro visible e infrarrojo cercano, contiene 5 bandas incluida la banda pancromática. Dispone de 5 modos de adquisición, la descarga de datos se realiza en la banda X y contiene una memoria a bordo de 1 Terabit.

Características Principales del Satélite PerúSAT-1	Información	
Misión	Observación de la tierra	
Vida estimada	10 años mínimo	
Ancho de imagen	14.5 km	
Peso del Satélite	400 kg	
Instrumento Óptico	Carburo de silicio de la familia NAOMI	
Duración de órbita	98.79 min	
Parámetros de Monitoreo diario	4 421	
Capacidad de 63 000 km ² (300 imágenes) almacenamiento diario		
Velocidad del satélite	7.5 km/seg.	
Altitud de Órbita	702.5 km	

Tabla Nº 2: Características del Satélite PerúSAT-1

Bandas espectrales	Nombre	Rango espectral (nm)	Resolución espacial (m)
	Azul (B1)	0.454 - 0.525	2.8
	Verde (B2)	0.533 - 0.598	2.8
	Rojo (B3)	0.633 - 0.702	2.8
	Infrarrojo cercano (B4)	0.764 - 0.884	2.8
	Pancromático (PAN)	0.451 - 0.745	0.7
Resolución radiométrica	16 bits		
Resolución temporal	26 días		
Capacidad estereoscópica	Si		

Actualmente, la administración y control está a cargo de la Agencia Espacial del Perú - CONIDA, por medio del Centro Nacional de Operaciones de Imágenes Satelitales (CNOIS) ubicada en la estación terrena en Punta Lobos (Pucusana - Lima)

7.2.2. Datos meteorológicos

Se utilizaron los datos históricos de precipitación y temperatura del aire de las 4 estaciones disponibles en la provincia de Morropón con el propósito de conocer la climatología del lugar en estudio.

Tabla N°3: Descripción de estaciones meteorológicas utilizadas

N°	Estación	Latitud	Longitud	Altitud
1	Hacienda Bigote	-5° 19' 15.2''	-79° 47' 8.47''	198 m
2	Morropon	-5° 11' 40.72''	-79° 58' 15.87''	128 m
3	San Pedro	-5° 4' 46.34''	-80° 0' 58.31''	240 m



Figura N°2: Ubicación de estaciones meteorológicas en la provincia de Morropón -

Dentro de los límites de la provincia de Morropón se ubican 4 estaciones meteorológicas (Figura N° 02), la estación de la hacienda Bigote ubicada en el distrito de San Juan de Bigote, la estación de Morropón y San Pedro ubicada en del distrito de Morropón y la estación de Chulucanas ubicada en del distrito del mismo nombre.

7.3. Análisis de los datos y cálculos de índices

Con el fin de alcanzar los objetivos establecidos se analizaron las siguientes etapas :

a. Procesamiento de las imágenes satelitales

En cuanto al registro histórico de imágenes satelitales disponibles del sensor MODIS, se trabajó con el promedio de temperatura superficial e índice NDVI mensuales, para un análisis del comportamiento temporal del índice de sequía planteado en esta investigación.

b. Análisis de frecuencia de los datos:

Se elaboró un script en el entorno de R Studio para estimar la frecuencia de datos disponibles en cada píxel, cuya función es reemplazar los valores existentes en un pixel por el valor de "1" y si no están presente reemplazarlos por el valor de "0", esto se aplicó a la serie temporal de imágenes satelitales, con la finalidad de excluir las zonas que tengan disponibilidad de datos inferior al 30% y solo considerar zonas que si superan este 70% de datos en su serie de tiempo.

Cabe recalcar que esta ausencia de datos en el pixel se debe generalmente a la presencia de una nube de tormenta.

c. Cálculo del índice VHI

El índice de condición vegetal (VCI, siglas en inglés) propuesto por Kogan (1990) y el Índice de condición de temperatura (TCI, siglas en inglés) por Kogan (1997), estimados a partir del rango espectral que identifica la cobertura vegetal y el rango térmico para la temperatura superficial del suelo, respectivamente. Ambos al relacionarse, permiten un estudio adecuado de las sequías asociadas al estrés hídrico de los cultivos y el aumento de la temperatura superficial.

$$VCI = 100 * \frac{\left(NDVI_{i} - NDVI_{min}\right)}{\left(NDVI_{max} - NDVI_{min}\right)}$$
(1)

Se tiene el índice de condición de vegetación (VCI), donde $NDVI_{max}$ y $NDVI_{min}$ representan los valores máximos y mínimos de vegetación analizados en una serie temporal y $NDVI_i$ son los valores de índice de vegetación de la imagen instantánea a analizar

$$TCI_{c} = 100 * \frac{(LST_{max} - LST_{c})}{(LST_{max} - LST_{min})}$$
(2)

Para el caso de la temperatura superficial se considera LST_{max} y LST_{min} la temperatura superficial máxima y mínima analizados en

una serie temporal y LST_c son los valores de temperatura superficial de la imagen instantánea a analizar para obtener el índice de condición de temperatura superficial (TCI_c) propuesto en el estudio de la NASA (Levent A., et al., 2018)

El VCI y TCI_c Comprenden valores que varían de 0 a 100 para condiciones desfavorables y favorables, respectivamente.

$$VHI = 0.5 * VCI + 0.5 * TCI_{C}$$
(3)

Tabla N°4: esquema de clasificación del VHI. Fuente: Kogan, 1995 (traducido por: Jose Coello).

VHI	Clase de sequía	Nivel
< 10	Extrema	1
< 20	Severa	2
< 30	Moderada	3
< 40	Medio	4
> 40	No hay efectos	5

Fuente: Kogan, 1995

El índice de vegetación de salud (VHI, siglas en inglés) relaciona la salud general de la vegetación y se asocia a condiciones de sequías según su severidad (Tabla N°4) y la evaluación de su rendimiento.

d. Prueba de Mann Kendall (MK) para detección de tendencias

La prueba de MK, también llamada prueba de Kendall tau por Mann (1945) y Kendall (1975), es la prueba no paramétrica basada en el rango para evaluar la importancia de una tendencia, y ha sido ampliamente utilizada en detección de tendencias en estudios hidrológicos. La hipótesis nula HO: No existe una tendencia en la serie {Xi, i= 1, 2 ... n}. La hipótesis alternativa es H1: Hay una tendencia en la serie.

El estadístico S de Tau de Kendall se define como sigue (Yue et al., 2002).

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^{n} sgn(X_j - X_i)$$
 (1)

Donde el X j son los valores de datos secuenciales, n es la longitud del conjunto de datos, y:

$$sgn(\Theta) = \{1 \ si \ \Theta > 0\}$$
(2)
$$sgn(\Theta) = \{0 \ si \ \Theta = 0\}$$
(3)
$$sgn(\Theta) = \{-1 \ si \ \Theta < 0\}$$
(4)

Mann (1945) y Kendall (1975) han documentado que cuando $n \ge 8$, la estadística S es aproximadamente normal distribuido con la media y la varianza de la siguiente manera:

$$E(S) = 0 \quad (5)$$

$$V(S) = \frac{n(n-1)(2n+5) - \sum_{m=1}^{n} t_m m(m-1)(2m+5)}{18} \quad (6)$$

Donde t_m Es el número de vínculos de grado m. La prueba estadística estandarizada Z se calcula:

$$Z = \{\frac{S-1}{\sqrt{V(S)}} \quad S > 0 \ 0 \qquad S = 0 \ \frac{S+1}{\sqrt{V(S)}} \quad S < 0$$
(7)

El valor de probabilidad P de la estadística S de MK para datos de la muestra se puede estimar usando la función de distribución cumulativa normal como:

$$P = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{z} e^{-t^{2}/2} dt$$
 (8)

Siendo el resultado de Z igual o mayor que 1,96 representa valor positivo, lo que indica existencia de tendencia significativa creciente (Tsc);siendo el resultado de Z menor que 1,96 demuestra tendencia no significativa creciente (Tnsc); cuando el resultado de Z es igual o menor que -1,96 indica valor negativo y tendencia significativa decreciente (Tsd), y cuando Z presenta resultado mayor que -1,96 indica tendencia no significativa decreciente (Tnsd) (tabla 5) (Alves et al., 2015).

SIGNIFICANCIA	SIMBOLOGÍA	Z
Sin tendencia	ST	0
Tendencia significativa creciente	TSC	> +1.96
Tendencia significativa decreciente	TSD	< -1.96
Tendencia no significativa creciente	TNSC	< +1.96
Tendencia no significativa decreciente	TNSD	> -1.96

Fuente: Alves et al. 2015 (adaptado por Alencar, et al. 2017)

e. Autocorrelación y Correlación Cruzada

Nelson-Wong et al., (2009) nos explica que la autocorrelación y la correlación cruzada difieren de la correlación de momento del producto de Pearson en que las señales que varían en el tiempo se utilizan en lugar de puntos discretos de múltiples muestras o participantes. Con la autocorrelación, una señal variable en el tiempo (x[t]) se correlaciona consigo misma. La correlación cruzada implica correlacionar 2 señales diferentes que varían en el tiempo, x(t) e y(t), entre sí. Además, menciona que ambos procesos implican el desplazamiento iterativo de la señal hacia adelante y hacia atrás en el tiempo contra la otra señal que se mantiene estacionaria con un valor de correlación, Rxy, que se calcula en cada incremento (Figura N°03), se realiza un proceso similar para la correlación cruzada, con la excepción de que las 2 matrices de datos que se correlacionan no son las mismas. Las funciones de autocorrelación y correlación cruzada consisten en una serie de tiempos de valores r de Pearson, donde cada valor Rxv describe la relación lineal entre cada punto en las señales de entrada en cada cambio incremental. Otro aspecto importante es que cada punto de datos en las señales de entrada está incluido y tiene el mismo peso en el cálculo de Rxy. La función de autocorrelación Rxx tiene

por definición un valor pico de +1 en el desplazamiento de fase cero, porque las señales en el desplazamiento de fase cero son idénticas. La función de correlación cruzada Rxy tiene su valor máximo que ocurre en el cambio de fase, donde las 2 señales son más similares entre sí.

Figura N°3: Demostración esquemática del proceso computacional de una autocorrelación.



f. Modelos de media móvil integrada autorregresiva (ARIMA)

Para modelar series de tiempo, podemos trabajar con los modelos estadísticos tradicionales, incluido el promedio móvil, el suavizado exponencial y ARIMA. Estos modelos son lineales ya que los valores futuros están limitados para ser funciones lineales de datos pasados. Durante las últimas décadas, los investigadores se han centrado mucho en los modelos lineales, ya que habían demostrado su simplicidad en la comprensión y la aplicación.

Los modelos de predicción de series de tiempo se utilizan principalmente para predecir la demanda. Bajo una hipótesis de promedio móvil autorregresivo, (Kurawarwala & Matsuo, 1998) calcularon la variación estacional de la demanda usando datos históricos y validaron los modelos examinando el desempeño del pronóstico.

Miller & Williams (2003) mezclaron factores estacionales en su modelo para mejorar la precisión del pronóstico, los factores estacionales se calculan a partir del modelo multiplicativo. Hyndman (2004) amplió el trabajo de (Miller & Williams, 2003) aplicando diferentes relaciones entre tendencia y estacionalidad bajo la hipótesis ARIMA estacional. El enfoque ARIMA clásico se vuelve prohibitivo y, en muchos casos, es imposible determinar un modelo cuando el orden de ajuste estacional es alto o sus diagnósticos no indican que la serie de tiempo es estacionaria después del ajuste estacional. En tales casos, los parámetros estáticos del modelo ARIMA clásico se consideran la principal limitación para pronosticar una alta demanda estacional variable. Otra restricción del enfoque ARIMA clásico es que requiere una gran cantidad de observaciones para determinar el modelo de mejor ajuste para una serie de datos.

Un modelo ARIMA se etiqueta como modelo ARIMA (p, d, q), en el que:

- p es el número de términos autorregresivos;
- d es el número de diferencias; y
- q es el número de medias móviles.

<u>El proceso autorregresivo.</u> Los modelos autorregresivos asumen que Yt es una función lineal de los valores anteriores y viene dada por la ecuación (1)

$$Y_t = \alpha_1 Y_{t-1} + \varepsilon_t \quad (1)$$

Literalmente, cada observación consta de un componente aleatorio (choque aleatorio, ϵ) y una combinación lineal de las observaciones anteriores. a1 en esta ecuación es el coeficiente de auto regresión.

<u>El proceso integrado.</u> El comportamiento de la serie temporal puede verse afectado por el efecto acumulativo de algunos

procesos. Por ejemplo, el estado de las existencias se modifica constantemente por el consumo y la oferta, pero el nivel medio de las existencias depende esencialmente del efecto acumulativo de los cambios instantáneos durante el período entre inventarios.

Si bien los valores de las acciones a corto plazo pueden fluctuar con grandes contingencias en torno a este valor promedio, el nivel de la serie a largo plazo se mantendrá sin cambios. Una serie de tiempo determinada por el efecto acumulativo de una actividad pertenece a la clase de procesos integrados. Incluso si el comportamiento de una serie es errático, las diferencias de una observación a la siguiente pueden ser relativamente bajas o incluso oscilar alrededor de un valor constante para un proceso observado en diferentes intervalos de tiempo. Esta estacionalidad de la serie de diferencias para un proceso integrado, es una característica crucial desde el lado del análisis estadístico de la serie de tiempo. Los procesos integrados son el arquetipo de las series no estacionarias. La diferenciación de orden 1 supone que la diferencia entre dos valores sucesivos de Y es constante.

Un proceso integrado se define mediante la ecuación (2)

$$Y_t = Y_{t-1} + \varepsilon_t \quad (2)$$

donde la perturbación aleatoria es un ruido blanco.

<u>El proceso de media móvil.</u> El valor actual de un proceso de pre -mediación móvil es una combinación lineal de la perturbación actual con una o más perturbaciones anteriores. El orden de la media móvil indica el número de períodos incrustados anteriores en el valor actual. Por tanto, una media móvil se define mediante la ecuación (3)

$$Y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (3)$$

Para encontrar los parámetros p,d ,q, P, D y Q del modelo ARIMA, se utilizó el comando auto.arima en 1000 puntos al azar dentro de la zona de estudio, con la cual encontraremos los parámetros más repetitivos y se utilizaran para el modelo ARIMA.Dichos parámetros serán utilizados en el modelo ARIMA para el índice VHI, en el cual se usarán el 96% de los datos para la calibración del modelo y el 4% para la validación.

g. Medidas de precisión

Según (Jollife, I. T. et al. 2003, p.26), para evaluar la calidad de los pronósticos existen medidas de precisión (accuracy), medidas de asociación, y medidas de capacidad o destreza (skill). El análisis de medidas de precisión hoy es el más utilizado al evaluar estadísticamente pronósticos de variables discretas de modelos de predicción numérica, sobre todo las el error medio absoluto (MAE), la raíz del error cuadrático medio RMSE y el coeficiente de correlación.

Según (Willmott, C. J., 1982), para analizar los errores de pronóstico se deben calcular e interpretar como mínimo, las siguientes medidas: la media de los valores observados (O), la media de los valores pronosticados (P), la desviación estándar de los variable pronosticada (S_P), la desviación estándar de la variable observada (S_O), el intercepto de la ecuación de regresión lineal (a), la pendiente de la ecuación de regresión lineal (b), el error absoluto medio MAE, la raíz del error cuadrático medio RMSE, el coeficiente de correlación (r), y por último el índice de Willmott. Como tanto el MAE como el RMSE son medidas que no tienen valores límites, (Willmott, C. J., 1982) hace uso de un índice de Concordancia (d), que para el presente estudio se llamará índice de Willmott y que se explicará más adelante.

De ese modo, las siguientes medidas de precisión son las medidas de mayor uso hoy en día al evaluar pronósticos y/o resultados de simulación:

<u>A. Sesgo o bias</u>

El sesgo o bias es la diferencia entre la media de los valores simulados con la media de los valores observados. Aunque (Wilks, D.

S., 2006) no considera a esta medida una medida de precisión en sí, esta medida es importante para evaluar qué tan alejado está la media de los valores simulados con los valores observados. Pronósticos que son, en promedio, subestiman a las observaciones presentarán un bias > 0, y pronósticos que, en promedio, subestiman a las observaciones presentarán un bias < 0. (Jollife, I. T. et al. 2003, p.21) recomienda que este valor debe ser pequeño tomando en cuenta que un bias de cero significa que las medias de los pronósticos y de las observaciones son exactamente iguales, aun cuando existiera un error de pronóstico. Esta medida se calcula de la siguiente forma:

$$bias = \frac{1}{N} \sum_{i=1}^{N} (P_i - O_i)$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (*Pi*, *Oi*))

Pi : Valor simulado en el tiempo *i*

Oi : Valor observado en el tiempo i

<u>B.</u> RMSE

La raíz del error cuadrático medio, RMSE por sus siglas en inglés, es la medida de precisión más usada para evaluar pronósticos. Esta medida es sensible a valores atípicos (outliers) presentes en la muestra de datos, ya que los errores derivados de estos valores atípicos son elevados al cuadrado. Una estimación exacta de los valores observados daría como resultado un RMSE de cero, que sería lo ideal; por eso siempre se busca que este valor sea el menor posible para interpretar una determinada precisión en los resultados de la simulación. Si no se tomará la raíz cuadrada de esta medida, esta no tendría las mismas unidades que las variables analizadas. El RMSE se calcula de la siguiente forma:

$$RMSE = \left\{ \frac{1}{N} \sum_{i=1}^{N} (P_i - O_i)^2 \right\}^{1/2}$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (*Pi*, *Oi*))

Pi : Valor simulado en el tiempo i

Oi : Valor observado en el tiempo i

C. Coeficiente de correlación (r)

Uno de los grados de asociación más comunes que se dan en la naturaleza es el grado de asociación lineal entre estos dos conjuntos de datos. Esta asociación lineal se calcula con uno de los estadísticos más utilizados actualmente llamado Coeficiente de Correlación de Pearson o simplemente Coeficiente de Correlación.

El grado de asociación lineal entre las variables X e Y significa el grado al cual los puntos de la gráfica de dispersión de las variables X e Y están cerca de una línea recta. Sin embargo, el análisis de la validación de pronósticos en muchos casos involucra saber que tan alejado están los valores pronosticados y las observados de ser exactamente iguales, y para lograr eso el análisis de dispersión debe hacerse con respecto a una recta ideal donde los valores de la variable X deben ser exactamente iguales a los valores de la variable Y.

Para hallar el Coeficiente de Correlación se deben cumplir dos condiciones, primero que las variables X (temperaturas observadas) e Y (temperaturas simuladas) sean variables aleatorias, y segundo, que la variación de estas dos variables genere una distribución de probabilidad bivariada normal. Para el caso de la primera condición se asumirá que tanto las variables X como Y son variables aleatorias y que por lo tanto son independientes, aunque esto no sea del todo cierto cuando se analiza variables meteorológicas (Wilks, D. S. 2006, p.143), y para el caso de la segunda condición,

según (Wilks, D. S. 2006, p.88), estos dos conjuntos de datos (observados y simulados) pueden comportarse como elementos de una distribución normal bivariado.

El Coeficiente de Correlación es sensible a outliers, sin embargo, no es sensible a los errores de pronóstico (RMSE o MAE), siempre y cuando estos errores sean regulares. De ese modo se puede tener una correlación muy buena y sin embargo un error promedio grande. Existen varias formas de calcular el valor del Coeficiente de Correlación. Tener en cuenta que el Coeficiente de Correlación de Pearson varía entre -1 y 1. Un valor de 1 indica una correlación perfecta, pero negativa donde las dos variables son inversamente proporcionales; un valor de cero indica ninguna relación lineal; y un valor de 1 indica una variación lineal conjunta ideal, donde las dos variables son directamente proporcionales. Se prefiere mostrar la fórmula utilizada en (Ramachandran, K. M. et al., 2009) por la simplicidad del cálculo.

$$r = \frac{\sum_{i=1}^{N} (X_i - \overline{X})(Y_i - \overline{Y})}{\sqrt{\sum_{i=1}^{N} (X_i - \overline{X})^2 \sum_{i=1}^{N} (Y_i - \overline{Y})^2}} ; -1 \le r \le 1$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (*Pi*, *Oi*))

Xi : Variable independiente (podría ser temperatura observada en el tiempo i)

Yi : Variable dependiente (podría ser temperatura simulada en el tiempo i)

8. Caracterización del área de estudio

8.1 Ámbito de investigación

El área de estudio comprende parte norte del territorio peruano en la provincia de Morropón, departamento de Piura. La Provincia de Morropón,

se ubica en la parte alta de la cuenca del río Piura (Figura N°04), al este de la ciudad de Piura, limita al Norte con la provincia de Ayabaca, al este con la provincia de Huancabamba, al sur con el departamento de Lambayeque y al oeste con la provincia de Piura. Es una de las ocho provincias que conforman el departamento de Piura (CAM, 2014).

La provincia de Morropón tiene una superficie de 3 817.92 Km2, siendo el distrito de mayor extensión el de la Matanza con 1 039.46 Km2; seguido del distrito capital Chulucanas con 871.19 Km2 y Salitral con 614.03 Km2. Está conformada por 10 distritos, Chulucanas, Buenos Aires, Chalaco, La Matanza, Morropón, Salitral, San Juan de Bigote, Santa Catalina de Mossa, Santo Domingo y Yamango. Según el Censo de 2007 tiene 159 693 habitantes, representando el 9.5% de la población regional, con una densidad poblacional de 41.8 hab/km2, siendo la población urbana mayoritaria con el 57%, mientras que la rural el 43%. Su tasa de crecimiento es la más baja en toda la región Piura (-0.2), debido a la migración principalmente de los jóvenes.

Figura N°4: Ubicación de Morropón



Climatología de Morropón

De las estaciones meteorológicas analizadas se obtuvo lo siguiente:

a. Estación Hacienda Bigote

En la ubicación de la estación Hacienda Bigote se aprecia que no se cuenta con datos de temperatura, pero sí de precipitación líquida, ya que es una estación pluviométrica, la cual tiene grandes valores entre los meses de enero y abril, teniendo su máximo en marzo con más de 160 mm.

Figura N°5: Diagrama climático de la estación meteorológica Hacienda Bigote.



b. Estación Morropón

En la estación Morropón se aprecia datos de temperatura máxima con el mínimo valor presente en Julio (29°C) y con valores superiores a 32°C en los meses de diciembre a enero, la de precipitación líquida, lluvia, la cual tiene un gran valor entre los meses de enero y abril, teniendo su máximo en marzo con más de 150 mm.



Figura Nº6: Diagrama climático de la estación meteorológica

c. Estación San Pedro

En la ubicación de la estación San Pedro se aprecia que no se cuenta con datos de temperatura, pero sí de precipitación líquida, siendo también una estación pluviométrica, la cual tiene grandes valores entre los meses de enero y abril, teniendo su máximo en marzo con más de 200 mm.



Figura N°7: Diagrama climático de la estación meteorológica San Pedro.

d. Estación Chulucanas

En la estación Chulucanas se aprecia datos de temperatura máxima con el mínimo valor presente en Julio (29°C) y con valores superiores a 32°C en los meses de diciembre a enero, la de precipitación líquida, lluvia, la cual tiene un gran valor entre los meses de enero y abril, teniendo su máximo en marzo con más de 120 mm.

Figura N°8: Diagrama climático de la estación meteorológica Chulucanas.



9. Resultados

9.1. Análisis de los datos:

Como resultado del análisis de disponibilidad de datos (Figura N°09) del sensor MODIS en la plataforma satelital AQUA y TERRA, respectivamente para la variable de NDVI durante el periodo 2002-2020 se evidencia pérdida de información en la zona este, debido principalmente a la presencia de nubes y por no cumplir con los criterios de calidad del pixel (efecto sombra, etc.).Además, se observa mayor disponibilidad de información sobre la plataforma TERRA, en comparación a AQUA, siendo la principal causa la hora del paso satelital sobre el área de interés.

Figura N° 9: Frecuencia de datos NDVI disponibles en % para satélite a) AQUA y b)TERRA





Figura N°10: Frecuencia de datos LST disponibles en % para satélite a) AQUA y b)TERRA MODIS-TERRA



Por otro lado, la disponibilidad de información (Figura N°10) para la variable de temperatura superficial (LST) se observa para el periodo 2002-2020 píxeles que no cumplieron con los estándares de calidad del dato en la zona este. Mediante un análisis comparativo se observa mayor disponibilidad de datos para la plataforma TERRA, durante el periodo 2002-2020. Es por ello que el análisis de los eventos de sequías serán considerados con datos obtenidos por la plataforma TERRA.

9.2. Distribución espacial de registro histórico de sequía agrícola

De la caracterización de sequías en base a la intensidad (Tabla N°3) se obtuvieron 5 categorías según la clasificación de extrema, moderada, severa, media y sin efecto (Figura N°11). Sobre la zona de Matanza y Chulucanas las intensidades de sequía extrema y severa a causa del tipo de cobertura superficial que identifica como desierto, según el mapa de uso de suelo.



Figura N°11: Mapa de peligro de sequía agrícola MODIS-TERRA

Por otro lado, la intensidad de sequía moderada y media son identificadas sobre zonas de actividad agrícola, las cuales se realizan entre los 500 hasta los 1500 msnm, sobre los 1500 msnm se aprecia que no hay efecto de sequía agrícola ; además, la intensidad severa y extrema se presenta por debajo de los 200 m.s.n.m.

9.3. Análisis de tendencia

De la descripción (Tabla N°5) de la significancia del test Mann - Kendall, se observa sobre la localidad de Morropón valores que no superan el umbral de +-1.96, es decir, no se presentan gran variabilidad entre los valores de VHI.



Figura 12: Mapa de tendencia Mann-Kendall VHI MODIS-TERRA

9.4. Comparación VHI y precipitación

Del análisis temporal para la estación meteorológica de Hacienda Bigote (Figura N°13), no se observan datos faltantes para la variable de precipitación en el periodo 2002 al 2020. Caso contrario sucede para la variable de VHI sobre la estación en análisis para determinados periodos en la serie temporal. Del correlograma entre la variable de precipitación y VHI se observa una mejor correlación en un periodo de desfase de -2 meses.



Figura 15: Validación cruzada de Precipitación y VHI 2002-2020

Analizando el desfase en la serie temporal (Figura N°14) entre ambas variables con la finalidad de identificar el efecto de la ausencia de precipitación sobre una sequía agrícola, se obtuvo una mejor correlación para un desfase de 2 meses, es decir, las consecuencias de un evento de sequía agrícola, se expresan 2 meses después, producto de la ausencia o retraso de la precipitación (tasas de precipitación fuera de los rangos mínimos). Se observa (Figura N°15) una mejor correlación de 0.36 para un t-2.





Para el caso de la estación meteorológica de Morropón (Figura N°16), no se observan datos faltantes para la variable de precipitación en el periodo 2002 al 2020. Sin embargo, sobre el píxel de la estación se tiene datos faltantes del índice VHI. Del correlograma (Figura N°17) se observa de manera similar a la estación hacienda Bigote una mejor correlación con un retraso de 2 meses(Figura N°18), donde se registra la mayo correlación de 0.39.





Sobre la estación meteorológica de Morropón (Figura N°19), no se observan datos faltantes para la variable de precipitación en el periodo 2002 al 2020. Sin embargo, sobre el píxel de la estación se tiene datos faltantes del índice VHI. Del correlograma (Figura N°20) se observa un comportamiento similar a las estaciones vecinas en la correlación (Figura N°21) entre los registros de precipitación y el índice de sequía con un valor de 0.42.



Finalmente, sobre la estación de Chulucanas (Figura N°22) se observa datos faltantes sobre la estación para el índice de VHI. Del correlograma (Figura N°23), se observa un mejor grado de correlación (Figura N°24) similar a las estaciones analizadas anteriormente con un grado de correlación de 0.38

- 9.5. Modelo ARIMA
- 9.5.1. Hiperparametros

Mediante un script desarrollado en Rstudio se analizaron los parámetros (Figura N°25) del modelo ARIMA. Siendo los no estacionarios p, d y q con valores óptimos de 5, 0 y 0 ,respectivamente; para el caso de los parámetros estacionarios P, D y Q se consideró 0,1 y 0 , respectivamente.



Figura 25: Histograma de hiperparametros más frecuentes para el modelo ARIMA

9.5.2. Validación del modelo ARIMA



Figura 26: Mapa de RMSE del VHI observado y VHI pronosticado Del modelo autorregresivo ARIMA, las medidas de precisión, muestran la fiabilidad del modelo (Figura N° 26) cuando el RMSE tenga valores cercanos a cero y esto se observa sobre el noreste de Chalaco, al igual que al sur de La Matanza. Caso contrario se aprecia sobre la localidad de Buenos Aires que presenta valores muy altos, es decir, los valores simulados por el modelo autorregresivo ARIMA no son muy precisos en esa ubicación.



Figura 27: Mapa de BIAS del VHI observado y VHI pronosticado Los lugares de sobreestimación y subestimación del valor real se analizan mediante el BIAS (Figura N° 27) se observa al noreste de Chalaco y Santo Domingo un BIAS con valores cercanos al 0, lo cual indica que no se subestima el valor real, caso contrario sucede sobre Buenos Aires, donde se subestima el valor real. Finalmente, sobre el nor-oeste de chulucanas y morropón se observa una ligera subestimación del valor real.



Figura 28: Mapa de correlación del VHI observado y VHI pronosticado

De los parámetros establecidos del modelo autorregresivo ARIMA, se observa un mayor grado de asociación entre los valores pronosticados y los observados en gran parte de la zona noreste de Morropón con valores superiores a 0.5, lo cual indica que el modelo escogido representa mejor las condiciones de sequías agrícolas sobre Santo Domingo, Chalaco, Santa Catalina de Mossa, Buenos Aires, Morropon, Noreste de Chulucanas, San Juan de Bigote y al este de Salitral.

10. Conclusiones

 Del análisis temporal de 20 años sobre el comportamiento de la cobertura vegetal y la temperatura superficial del suelo de productos MODIS, se obtuvo el índice de salud vegetal (VHI),patrones mensuales y anuales en la ocurrencia de sequías agrícolas con niveles de intensidad moderado, severo y extremo.

- Para la región de Morropón, se observa que existen menos datos disponibles del producto MOD11, LST/emissivity respecto al MOD13, debido a las condiciones del tiempo atmosférico en el lugar y el proceso de calidad de pixel.
- Los eventos de sequías extremas y severas en Morropón se registraron con mayor frecuencia en zonas menores de 250 m.s.n.m. siendo estas las áreas desérticas, para el caso de las zonas agrícolas, ubicadas entre los 500 a 1000 m.s.n.m, se aprecian las áreas de sequía agrícola moderada
- El VHI es un índice muy útil para identificar sequías de tipo agrícola;además, con el uso del modelo autoregresivo ARIMA nos permitió identificar áreas potenciales a ser afectadas por la sequía agrícola.
- Del grado de correlación entre las precipitaciones registradas en las estaciones meteorológicas analizadas y los registros de eventos de sequía agrícola, se observa que la ausencia de precipitaciones (falta de lluvias o acumulados diarios por debajo de lo normal) generan condiciones favorables para un escenario de sequía agrícola después de un periodo de 2 meses, es decir, se puede prevenir una sequía agrícola con 2 meses de anticipación si se realiza un monitoreo a la precipitación sobre las zonas de interés.

11. Recomendaciones

 En el caso de trabajar con diferentes sensores, se recomienda que las imágenes tengan el mismo tamaño del píxel (hacer un resampleo), como es el caso la Imagen MOD11 que tiene menor resolución espacial que la imagen MOD13. Además, se recomienda que para los próximos estudios se apliquen más imágenes del sistema satelital peruano PeruSat-1,lo cual permite mayor detalle en la captación de información radiométrica de la superficie.

- Realizar un monitoreo continuo sobre zonas propensas a sequías agrícolas usando técnicas de teledetección que permitan identificar zonas afectadas por este fenómeno en diferentes zonas del territorio peruano.Permitiendo cuantificar los cambios y pérdidas sobre áreas de interés; además de poder verificar el modelo propuesto en el presente trabajo.
- Implementar esta metodología en otras localidades y/o gobiernos regionales que son afectados por sequías para, además se recomienda a futuro aplicar imágenes de mayor resolución.

12. Bibliografía

- Adede, C., Oboko, R., Wagacha, P. W., & Atzberger, C. (2019). A
 Mixed Model Approach to Vegetation Condition Prediction Using
 Artificial Neural Networks (ANN): Case of Kenya's Operational
 Drought Monitoring. Remote Sensing, 11(9), 1099.
 https://doi.org/10.3390/rs11091099
- kogha, N., Edirisinghe, M., & Ranagalage, M. (2021). Satellite-Based Meteorological and Agricultural Drought Monitoring for Agricultural Sustainability in Sri Lanka. Sustainability, 13(6), 3427. https://doi.org/10.3390/su13063427

Alencar da Silva Alves, K. M., & Silva Nóbrega, R. (2017). TENDENCIA

PLUVIOMÉTRICA Y CONCENTRACIÓN ESTACIONAL DE PRECIPITACIÓN EN LA CUENCA HIDROGRÁFICA DEL RÍO MOXOTÓ – PERNAMCUCO – BRASIL. Revista Geográfica de América Central, 1 (58), 295. https://doi.org/10.15359/rgac.58-1.12

- Alves, T. L. B., Azevedo, P. V. de, & Farias, A. A. de. (2015). Rainfall behavior rain and its relationship with relief in the Regions Cariri of Eastern and Western state of Paraíba. Revista Brasileira de Geografia Física, 8(6), 1601-1614. https://doi.org/10.5935/1984-2295.20150090
- Becker, F., & Li, Z.-L. (1990). Towards a local split window method over land surfaces. International Journal of Remote Sensing, 11(3), 369-393. https://doi.org/10.1080/01431169008955028
- De la Cruz CCarhuaypiña, E. (s. f.). Analisis de estailidad mediante uso del programa Slide/V.2005 con la aplicacion al embalse cuchoquesera-Ayacucho,2003.
- Hyndman, R. J. (2004). The interaction between trend and seasonality. International Journal of Forecasting, 20(4), 561-563. https://doi.org/10.1016/j.ijforecast.2004.03.005
- ISDR. (s. f.). Living With Risk: An Integrated Approach to Reducing Societal Vulnerability to Drought.
- Justice, C. O., Townshend, J. R. G., Vermote, E. F., Masuoka, E., Wolfe, R. E., Saleous, N., Roy, D. P., & Morisette, J. T. (2002). An overview of

MODIS Land data processing and product status. Remote Sensing of Environment, 83(1-2), 3-15. https://doi.org/10.1016/S0034-4257(02)00084-6

- Justice, C. O., Vermote, E., Townshend, J. R. G., Defries, R., Roy, D. P.,
 Hall, D. K., Salomonson, V. V., Privette, J. L., Riggs, G., Strahler, A.,
 Lucht, W., Myneni, R. B., Knyazikhin, Y., Running, S. W., Nemani, R.
 R., Zhengming Wan, Huete, A. R., van Leeuwen, W., Wolfe, R. E., ...
 Barnsley, M. J. (1998). The Moderate Resolution Imaging
 Spectroradiometer (MODIS): Land remote sensing for global
 change research. IEEE Transactions on Geoscience and Remote
 Sensing, 36(4), 1228-1249. https://doi.org/10.1109/36.701075
- Karnieli, A., Agam, N., Pinker, R. T., Anderson, M., Imhoff, M. L., Gutman, G. G., Panov, N., & Goldberg, A. (2010). Use of NDVI and Land Surface Temperature for Drought Assessment: Merits and Limitations. Journal of Climate, 23(3), 618-633. https://doi.org/10.1175/2009JCLI2900.1
- Kogan, F. N. (1995). Application of vegetation index and brightness temperature for drought detection. Advances in Space Research, 15(11), 91-100. https://doi.org/10.1016/0273-1177(95)00079-T
- Kurawarwala, A. A., & Matsuo, H. (1998). Product Growth Models for Medium-Term Forecasting of Short Life Cycle Products. Technological Forecasting and Social Change, 57(3), 169-196. https://doi.org/10.1016/S0040-1625(97)00102-9

- Masuoka, E., Fleig, A., Wolfe, R. E., & Patt, F. (1998). Key characteristics of MODIS data products. IEEE Transactions on Geoscience and Remote Sensing, 36(4), 1313-1323. https://doi.org/10.1109/36.701081
- Miller, D. M., & Williams, D. (2003). Shrinkage estimators of time series seasonal factors and their effect on forecasting accuracy. International Journal of Forecasting, 19(4), 669-684. https://doi.org/10.1016/S0169-2070(02)00077-8

NASA. (2003). National Aeronautics and Space Administration.

- NASA. (2007). Science Plan For NASA's Science Mission Directorate 2007–2016.
- Nelson-Wong, E., Howarth, S., Winter, D. A., & Callaghan, J. P. (2009).
 Application of Autocorrelation and Cross-correlation Analyses in
 Human Movement and Rehabilitation Research. Journal of
 Orthopaedic & Sports Physical Therapy, 39(4), 287-295.
 https://doi.org/10.2519/jospt.2009.2969

OMM. (s. f.). Manual de indicadores e índices de sequía. 54.

Parkinson, C. (2000). EOS Data Products Handbook (Vol. 2).

Petitcolin, F., & Vermote, E. (2002). Land surface reflectance, emissivity and temperature from MODIS middle and thermal infrared data. Remote Sensing of Environment, 83(1-2), 112-134. https://doi.org/10.1016/S0034-4257(02)00094-9

- Snyder, W. C., Wan, Z., Zhang, Y., & Feng, Y.-Z. (1998). Classification-based emissivity for land surface temperature measurement from space. International Journal of Remote Sensing, 19(14), 2753-2774. https://doi.org/10.1080/014311698214497
- Snyder, W. C. & Zhengming Wan. (1998). BRDF models to predict spectral reflectance and emissivity in the thermal infrared. IEEE Transactions on Geoscience and Remote Sensing, 36(1), 214-225. https://doi.org/10.1109/36.655331
- Townshend, J. R. G., & Justice, C. O. (1986). Analysis of the dynamics of African vegetation using the normalized difference vegetation index. International Journal of Remote Sensing, 7(11), 1435-1445. https://doi.org/10.1080/01431168608948946
- Tucker, C. J. (s. f.). Red and Photographic Infrared I,Inear Combinations for Monitoring Vegetation. 24.
- Wilhite, D. A. (2000). Chapter 1 Drought as a Natural Hazard: Concepts and Definitions. 22.
- Wolfe, R. E., Roy, D. P., & Vermote, E. (1998). MODIS land data storage, gridding, and compositing methodology: Level 2 grid. IEEE Transactions on Geoscience and Remote Sensing, 36(4), 1324-1338. https://doi.org/10.1109/36.701082

World Meteorological Organisation. (2017). WMO statement on the

state of the global climate in 2016.

- Zhengming Wan, & Dozier, J. (1996). A generalized split-window algorithm for retrieving land-surface temperature from space. IEEE Transactions on Geoscience and Remote Sensing, 34(4), 892-905. https://doi.org/10.1109/36.508406
- Zhengming Wan & Zhao-Liang Li. (1997). A physics-based algorithm for retrieving land-surface emissivity and temperature from EOS/MODIS data. IEEE Transactions on Geoscience and Remote Sensing, 35(4), 980-996. https://doi.org/10.1109/36.602541
- Zuzulova, V., & Vido, J. (2018). Normalized difference vegetation index as a tool for the evaluation of agricultural drought in Slovakia. Ecocycles, 4(1), 83-87. https://doi.org/10.19040/ecocycles.v4i1.124