



UNIVERSIDAD NACIONAL AGRARIA LA MOLINA

PRESENTACIÓN DE PROYECTOS DE TESIS

ESCUELA DE POSGRADO

FORMULARIO : EPG 004



Señor

Director de la Escuela de Posgrado

Universidad Nacional Agraria La Molina

GOMEZ

Apellido Paterno

TUNQUE

Apellido Materno

KENNEDY RICHARD

Nombres

Alumno de la EPG en el Programa de Maestría [] o Doctorado [X] en

con Matrícula N° 20230937

Teléfono 967909039

e-mail ingkenri@gmail.com

RECURSOS HÍDRICOS

presento ante usted, para su aprobación, el Proyecto de Tesis titulado

Inteligencia artificial para pronosticar los patrones espaciales y temporales de ENOS en las regiones Niño, usando como predictores datos climáticos.

elaborado siguiendo las normas establecidas en el Reglamento de Tesis, revisado y aprobado por mi Asesor, Miembros de Comité Consejero y Coordinador del Programa.

Firma del Alumno

APROBACIÓN DEL COMITÉ CONSEJERO

Dr. Eusebio Mercedes Ingol Blanco

Asesor

1809

Codigo

Firma

Co - Asesor (*)

Codigo

Firma

Dr. Jesús Abel Mejía Marcacuzco

Miembro

0505

Codigo

Firma

Dr. Eduardo Abraham Chávarri Velarde

Miembro

0517

Codigo

Firma



PhD. Eusebio Ingol Blanco

V° B° Coordinador del Programa

Dr. Nestor Montalvo Arquíñigo

V° B° Director de la Unidad Posgrado

Director de la EPG-UNALM

La Molina, 11 de diciembre del 2023

(*) opcional

Nota: Presentar 02 originales de la presente solicitud y 01 ejemplar del Proyecto de Tesis para su revisión.

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

ESCUELA DE POSGRADO

DOCTORADO EN RECURSOS HÍDRICOS



PROYECTO DE TESIS:

Inteligencia artificial para pronosticar los patrones espaciales y temporales de ENOS en las regiones Niño, usando como predictores datos climáticos.

EJECUTOR:

Kennedy Richard Gomez Tunque

ASESOR:

Dr. Eusebio Mercedes Ingol Blanco

La Molina, 2023

I. INTRODUCCIÓN

El Niño Oscilación del Sur (ENOS), es uno de los principales impulsores de la variabilidad climática interanual del planeta (Philander, 1990), a menudo causa una amplia gama de anomalías climáticas, y el pronóstico anticipado de ENOS es siempre un tema científico importante y desafiante.

Dado que aún no se ha establecido una teoría ENOS unificada y completa, la comunidad científica a menudo usa indicadores relacionados, como el índice Niño 3.4, el índice de oscilación sur (SOI), el índice del Niño Oceánico (ONI). En el Perú además de utilizar lo antes mencionado utilizan el índice costero (ICEN) (Estudio Nacional del Fenómeno El Niño [ENFEN], 2012), basado en datos de la región Niño 1+2, esto para pronosticar las tendencias de desarrollo de ENOS a través de modelos de simulación numérica apropiados. Sin embargo, debido a que el fenómeno ENOS es un modelo altamente complejo, no lineal y dinámico (Barnston et al., 2012), los índices mencionados mezclan muchos componentes de baja y alta frecuencia, y la precisión de los métodos de pronóstico numérico populares actuales no es alta.

Cada año, investigadores de todo el mundo pronostican ENOS con meses de anticipación, y aun así siguen estudiando nuevos métodos de pronóstico todo el tiempo por su alta complejidad de pronóstico, incluyendo modelos dinámicos (modelos numéricos basados en leyes físicas de la océano - atmósfera), modelos estadísticos, modelos de redes neuronales artificiales y modelos de aprendizaje profundo.

Los avances recientes en el aprendizaje profundo, especialmente los enfoques de aprendizaje profundo para el pronóstico de secuencias espacio temporales (Shi X et al., 2018), proporcionan algunas ideas útiles sobre cómo analizar este problema. Los datos suficientes y el modelo adecuado se consideran dos puntos esenciales para aplicar los métodos de aprendizaje profundo de manera efectiva. Pero lo que se necesita es un modelo apropiado para el aprendizaje profundo de la región del pacífico relacionada con ENOS. Lo más importante del aprendizaje profundo es cómo capturar la información espacial y temporal simultáneamente en un modelo de aprendizaje profundo. Esta tarea es muy desafiante ya que

se ve afectada por los siguientes dos factores complejos como son: la dependencia espacial como la temperatura superficial del mar (TSM), y la dependencia temporal que se ve afectada por intervalos de tiempo modulada para las variaciones climáticas interanuales.

Dado que ENOS tiene enormes impactos en el clima a nivel global al inducir varias teleconexiones atmosféricas (Bjerknes, 1969; Wallace y Gutzler, 1981; Glantz et al., 1991), provocando casi de inmediato lluvias torrenciales, sequías, temperaturas elevadas e incluso descensos bruscos de la temperatura (Organización Meteorológica Mundial [OMM], 2014). En el caso de Perú el ENOS muestra una gran vulnerabilidad ante las variaciones climáticas drásticas, como los episodios de eventos extremos asociadas a ENOS, trayendo como consecuencia pérdidas económicas, y afectando las condiciones de vida de la población; es por eso, que el presente trabajo tiene como objetivo proponer un modelo de pronóstico mediante inteligencia artificial de los patrones espaciales y temporales de ENOS en las regiones Niño, teniendo como precursores datos climáticos oceánicos y atmosféricos espacio temporales.

II. JUSTIFICACIÓN DE LA INVESTIGACIÓN

Aproximadamente de dos a siete años, la temperatura de la superficie del mar es más alta (baja) que el promedio en el Pacífico ecuatorial oriental, junto con los cambios en la atmósfera (OMM, 2014). El ENOS es causado por una interacción océano-atmósfera a gran escala entre el Pacífico ecuatorial y la atmósfera global (Bjerknes, 1969), es el modo dominante de variabilidad climática en escalas de tiempo interanuales y tiene tele conexiones en todo el mundo (Bjerknes, 1969; Wallace y Gutzler, 1981; Glantz et al., 1991). Dado que ENOS causa enormes daños en todo el mundo, es muy deseable realizar pronósticos hábiles, preferibles para plazos de hasta 1 año. Hasta ahora, se utilizan modelos tanto estadísticos como dinámicos para predecir ENOS (Chen et al., 2004; Yeh et al., 2009; Fedorov et al., 2003). Sin embargo, los eventos ENOS no se pronostican lo suficientemente bien hasta con 6 meses de anticipación debido a la existencia de la llamada barrera de predictibilidad (Goddard et al., 2001; Goddard et al., 2009).

La mayoría de las investigaciones y modelos para pronósticos relacionadas a ENOS, como los modelos dinámicos entregan pronósticos de muy cortos plazos y son de altos costos computacionales, por otro lado, los modelos estadísticos, dependen en gran medida de la disponibilidad de datos históricos oceánicos y atmosféricos y se centra en investigar datos únicos de índices Niño (*SOI*, *MEI*, *ONI*). Estas investigaciones se enfocan en su mayoría en la región 3.4, y no en la región Niño 1+2, que, para Perú, ambas regiones tienen efectos muy devastadores, por cual es materia de investigación tanto en la región Niño 3.4 y Niño 1+2.

Por lo tanto, es necesario mejorar la habilidad de predicción de ENOS como un proceso espacio temporal más allá del límite de predictibilidad (6 meses), tanto en la región Niño 3.4 como la región Niño 1+2, en este caso usando técnicas de Redes Neuronales profundas. En este sentido, surge la siguiente interrogante de investigación:

¿Es posible pronosticar ENOS mediante un modelo de inteligencia artificial espacio temporal en las regiones Niño?

III. OBJETIVOS DE LA INVESTIGACIÓN

Los objetivos que persigue esta investigación son:

3.1. Objetivo general

- Pronosticar mediante inteligencia artificial los patrones espaciales y temporales de ENOS en las regiones Niño, teniendo como predictores datos climáticos oceánicos y atmosféricos espacio temporales.

3.2. Objetivos específicos

- Analizar y caracterizar los datos climáticos predictores oceánicos y atmosféricos de los eventos El Niño y La Niña de manera espacial y temporal.
- Pronosticar los cambios en la distribución espacial y temporal de las anomalías de la temperatura superficial del mar para eventos El Niño y La Niña, con datos climáticos oceánicos y atmosféricos.
- Pronosticar el desarrollo temporal de índices climáticos oceánicos y evaluar la habilidad de correlación del modelo de inteligencia artificial con los índices Niño 3.4 y Niño 1+2.
- Evaluar y comparar el modelo de inteligencia artificial con modelos de pronósticos climáticos globales de manera espacio temporal.

IV. FORMULACIÓN DE HIPÓTESIS

Dado que El Niño Oscilación del Sur representa condiciones climáticas heterogéneas, y está asociado con lluvias severas, inundaciones y sequías que afectan a todo el mundo, con un impacto socioeconómico y ambiental desastroso en muchos países, y más aún en el Perú (OMM, 2014), se plantean las hipótesis siguientes:

4.1. Hipótesis general

- Un modelo de inteligencia artificial espacio temporal puede pronosticar ENOS en las regiones Niño de manera espacio temporal.

4.2. Hipótesis específicos

- Los datos climáticos predictores oceánicos y atmosféricos tienen influencia física en los eventos El Niño y La Niña.
- Con datos climáticos oceánicos y atmosféricos se puede pronosticar la distribución espacial y temporal de las anomalías de la temperatura superficial del mar para eventos El Niño y La Niña.
- El modelo de inteligencia artificial propuesto puede pronosticar el desarrollo temporal de índices climáticos oceánicos.
- El modelo de inteligencia artificial propuesto se puede comparar con modelos de pronóstico climáticos globales de manera espacio temporal.

V. MARCO TEÓRICO

5.1. ANTECEDENTES

El desarrollo de la tecnología en los últimos años, ha ido impulsando notablemente al área de la inteligencia artificial (aprendizaje profundo, aprendizaje automático y redes neuronales artificiales). En ese sentido muchos investigadores ayudados de la inteligencia artificial han propuestos pronósticos de ENOS con distintas técnicas de la inteligencia artificial.

A continuación, se menciona el uso del aprendizaje profundo (DL, en sus siglas en inglés) en el pronóstico de ENOS y la manera de cómo está contribuyendo en el pronóstico de largo plazo. Geng et al. (2021), Chen et al. (2023) y Wang et al. (2023) pronosticaron mediante esta técnica el índice El Niño 3.4 de manera temporal a largo plazo (más de 1 año), en el caso de Geng et al. (2021) y Wang et al. (2023) utilizaron como datos de entrada mapas espacio temporales de las anomalías de la TSM. Además, Wang *et al.* (2023) le adicionaron el contenido de calor del océano de simulación históricos del CMIP5/6, obteniendo pronósticos a larga plazo del índice Niño 3.4.

Wang *et al.* (2023) pronosticaron ENOS, con datos de entrada de mapas espaciales de las anomalías de la TSM y la temperatura oceánica promediada verticalmente en los 300 m superiores, estos datos de entrada son simulaciones históricas de la fase 5/6 (CMIP5/6) e iniciando, con un filtrado y combinado de modelos CMIP mediante algoritmos genéticos para los datos de entrenamiento, y posteriormente realizando pronósticos de ENOS.

También la literatura muestra que para identificar ENOS se ha utilizado muchos índices climáticos, como por ejemplo ONI, Jonnalagadda y Hashemi (2022) usaron mapas característicos espaciales de la TSM para pronosticar temporalmente ONI en plazos de entrega de 1, 3, 6, 9 y 12 meses.

En el pronóstico de ENOS con DL, también hay investigaciones de pronóstico de ENOS basados en datos de entrada de series temporales como las anomalías de la SST, para pronosticar índices Niño, específicamente Niño 3.4 (serie temporal). Yan et al. (2020), Guo et al. (2020) y Chen et al. (2023), concluyeron que puede pronosticarse El Niño con 12 meses

de anticipación en promedio y con aceptables métricas estadísticas, estos autores pronostican solo de manera temporal el índice El Niño.

Así mismo, entre las técnicas de pronóstico, podemos mencionar las técnicas de aprendizaje automático (ML, en sus siglas en inglés), Pal et al. (2020) uso estas técnicas para el pronóstico de ENOS, evaluando dos algoritmos ML no lineales ampliamente utilizados, los cuales son, Regresión de Vectores de Soporte (SVR, en sus siglas en inglés) y Bosque aleatorio (RF, en sus siglas en inglés) para pronosticar el Índice Modoki ENOS (EMI, en sus siglas en inglés) para 6, 12, 18 y 24 meses, con una precisión razonable estadísticamente.

5.2. BASES TEORICAS

5.2.1. Inteligencia artificial

Las Redes Neuronales Artificiales (RNA), el Aprendizaje automático (*Machine Learning*), y el Aprendizaje Profundo (*Deep Learning*) están fuertemente ligados porque son los pilares que sustentan la Inteligencia Artificial (IA), en estas bases teóricas explicaremos los conceptos y demás conocimientos fundamentales necesarios para el desarrollo de la investigación respecto de la IA (Figura 1).

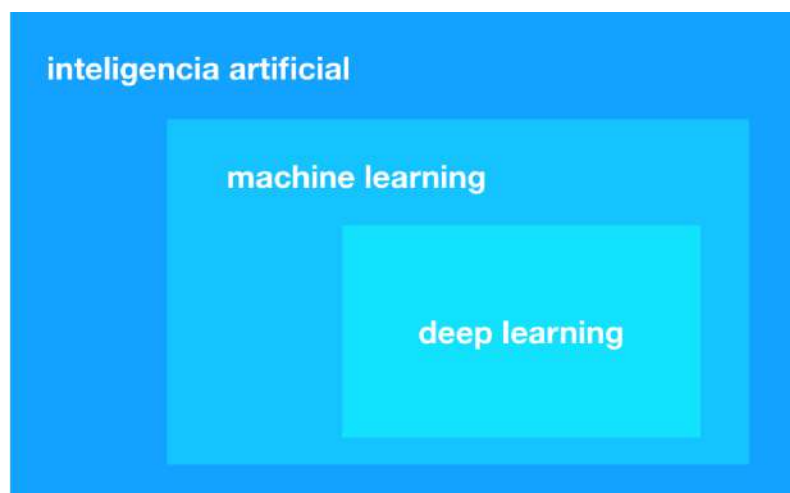


Figura 1: El aprendizaje profundo es parte del aprendizaje automático y este es un subconjunto de la Inteligencia artificial

a. Redes Neuronales Artificiales

McCulloch y Pitts (1943) propusieron un modelo muy simple de la neurona biológica, que más tarde se conoció como neurona artificial: tiene una o más entradas binarias (encendido/apagado) y una salida binaria. La neurona artificial activa su salida cuando más

de un cierto número de sus entradas están activas. En su artículo, demostraron que incluso con un modelo tan simplificado es posible construir una red de neuronas artificiales que calcula cualquier proposición lógica que se desee.

Una red neuronal artificial intenta imitar el cerebro en su nivel más básico, es decir, el de la neurona. Una neurona artificial tiene una estructura similar a la de una neurona humana y comprende las siguientes secciones (Figura 2).




Figura 2: Red Neuronal artificial

Fuente: Singh y Manure (2019)

b. Aprendizaje Automático

Como lo definió Samuel (1959), el aprendizaje automático es el campo de estudio que brinda a las computadoras la capacidad de aprender sin estar programadas explícitamente. El objetivo del aprendizaje automático es construir programas cuyo rendimiento mejore automáticamente con algunos parámetros de entrada, como datos, criterios de rendimiento, etc. Los programas se vuelven más impulsados por datos, en términos de toma de decisiones o predicciones. Puede que no nos demos cuenta, pero el aprendizaje automático se ha apoderado de nuestra vida diaria, desde recomendar productos en portales en línea hasta vehículos autónomos que pueden llevarnos del punto A al punto B sin que los conduzcamos o contratemos a un conductor.

El aprendizaje automático es parte de la inteligencia artificial y comprende principalmente tres tipos: Aprendizaje supervisado, Aprendizaje sin supervisión, Aprendizaje semi supervisado.

c. Aprendizaje profundo

El aprendizaje profundo es un subconjunto del aprendizaje automático, y trata de un conjunto de algoritmos y técnicas que tienen como fin el aprendizaje automático.

En esta sección se presenta el aprendizaje profundo supervisado, que incluye perceptrones multicapa (MLP, en sus siglas en inglés), las redes neuronales convolucionales (CNN, en sus siglas en inglés), las redes neuronales recurrentes (RNN, en sus siglas en inglés), las redes neuronales de memoria a corto y largo plazo (LSTM, en sus siglas en inglés) y la combinación de redes LSTM y redes Convolucionales denominado ConvLSTM.

5.2.2. El Niño Oscilación de Sur y el fenómeno del Niño

a. Fenómeno del Niño y corriente del Niño

Antes de describir el ENOS, es necesario conocer la evolución del fenómeno del Niño. Takahashi et al. (2014) en su artículo de divulgación comentaron que la primera descripción de un evento El Niño fue realizada por Carranza en 1891, refiriéndose a los sucesos de ese mismo año, que lo bautizó como “Corriente del Niño”, posteriormente lo hizo también Carrillo (1892), mencionando que, a fines del siglo XIX, los pescadores del norte del Perú apreciaron que todos los años hacia finales de diciembre, cerca de la Navidad, solía ocurrir un incremento de la temperatura del agua del mar, la cual era observable a lo largo de la costa norte. Atribuyeron este calentamiento a la llegada de una corriente marina de aguas cálidas a la que llamaron la corriente de “El Niño”.

El significado del fenómeno El Niño ha ido cambiando a lo largo de los años. En algunos países de Sudamérica como Perú y Ecuador, se denomina “El Niño” al incremento de la Temperatura Superficial del agua del Mar (TSM) en el litoral de la costa oeste de Sudamérica con ocurrencia de lluvias intensas.

b. El Niño Oscilacion de Sur

El Niño Oscilación del Sur (ENOS) se genera en el Pacífico tropical a través de interacciones entre la atmósfera y el océano, es una variación irregular periódica en los vientos y la TSM

(Philander, 1990; Bjerknes, 1969). Además, es la variación anual más energética del sistema climático en la Tierra, con eventos ENOS cálidos (El Niño) y eventos fríos (La Niña) que ocurren aproximadamente cada 2 a 7 años.

La fase de calentamiento del ENOS es lo que se conoce como El Niño, mientras que el periodo de enfriamiento es conocido como La Niña (Rasmusson y Carpenter, 1982).

Ambos fenómenos se pueden suceder, pero es importante señalar que el hecho de que El Niño tenga lugar, no necesariamente implica que el fenómeno de La Niña se produzca en el periodo inmediatamente posterior que le corresponde y viceversa. De hecho, hay periodos en los que ninguno de estos eventos tiene lugar y son denominados Neutros.

c. Efectos y condición de ENOS en el Pacífico Tropical

Condición normal: Normalmente, la temperatura de la superficie del mar es aproximadamente 8 °C más alta en el Pacífico occidental que las aguas de América del Sur. Esto se debe a los vientos alisios que soplan de este a oeste a lo largo del ecuador permitiendo el oleaje de agua fría y rica en nutrientes desde niveles más profundos frente a la costa noroeste de América del Sur (Figura 3).




Figura 3: Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones Normales

Fuente: McPhaden (2018)

Además, estos mismos vientos alisios empujan el agua hacia el oeste, que se acumula más alto en el Pacífico occidental. La altura media del nivel del mar es aproximadamente 46 cm

más alta en Indonesia que en Perú. Los vientos alisios, al acumular agua en el Pacífico occidental, hacen una capa cálida de 150 metros en el oeste que empuja la termoclina hacia abajo, mientras que se eleva en el este. La termoclina oriental de 30 metros poco profunda permite que los vientos tiren de agua desde abajo, agua que generalmente es mucho más rica en nutrientes que la capa superficial.

Condición de El Niño: Sin embargo, cuando los patrones de presión del aire en la dirección inversa del Pacífico Sur (la presión del aire en Darwin es más alta que en Tahití), los vientos alisios disminuyen en fuerza (y pueden invertir la dirección). El resultado es que el flujo normal de agua lejos de América del Sur disminuye y el agua oceánica se acumula fuera de América del Sur. Esto empuja la termoclina más profunda y una disminución en el oleaje (Figura 4).

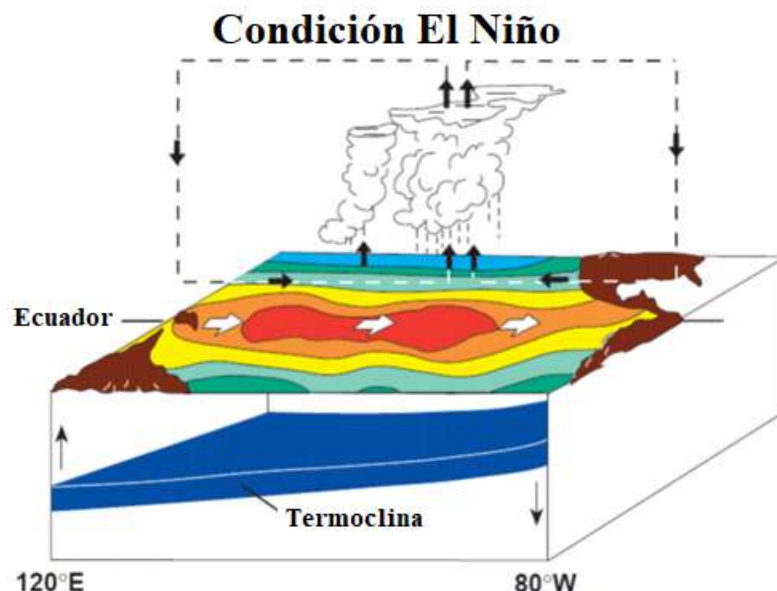


Figura 4: Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones El Niño

Fuente: McPhaden (2018)

Con una termoclina más profunda y disminución del transporte hacia el oeste de agua, la temperatura de la superficie del mar aumenta a mayor de lo normal en el Pacífico oriental. Esta es la fase cálida de la ENOS, llamada El Niño. El resultado neto es un cambio del patrón de lluvia predominante desde el Pacífico occidental normal hasta el Pacífico Central. El efecto es que las precipitaciones son más comunes en el Pacífico Central, mientras que el Pacífico occidental se vuelve relativamente seco.

Condición La Niña: Hay ocasiones en que los vientos alisios que soplan hacia el oeste a través del Pacífico tropical son más fuertes de lo normal, lo que lleva a un aumento del oleaje frente a América del Sur y, por lo tanto, a temperaturas más bajas de lo normal en la superficie del mar.

El patrón de lluvia predominante también se desplaza más al oeste de lo normal. Estos vientos acumulan agua superficial cálida en el Pacífico Occidental. Esta es la fase fría de ENOS llamada La Niña (Figura 5). Lo sorprendente es que estos cambios en las temperaturas de la superficie del mar no son grandes, más o menos 3 °C y generalmente mucho menos.

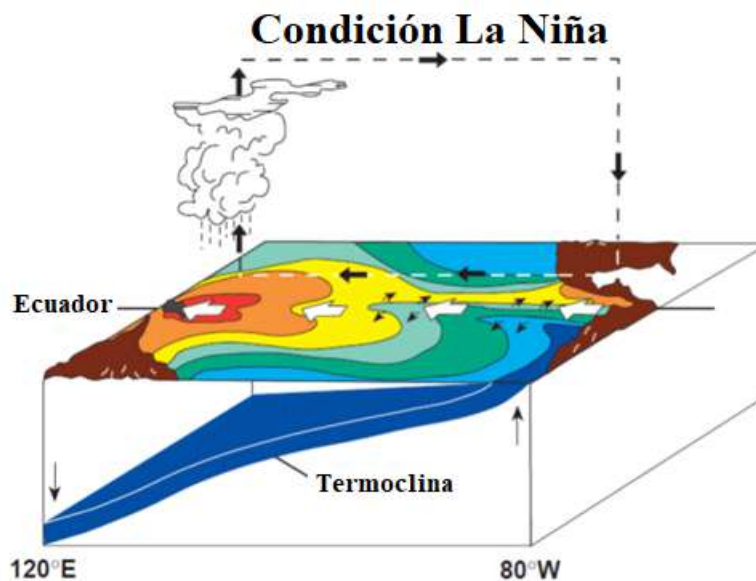


Figura 5: Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones La Niña

Fuente: McPhaden (2018)

d. Índices climáticos ENOS para identificar la variabilidad climática

Un índice climático se define como un valor que pueda describir el estado y los cambios en el sistema climático. El clima de un lugar en específico, es el estado promedio de la atmósfera, esto es, durante un periodo de tiempo prolongado, por lo que los cambios en el clima son más lentos que los del tiempo, ya que éste puede cambiar bruscamente cada día.

Se mencionan algunos índices climáticos más utilizados para identificar ENOS como, ONI (Oceanic Niño Index), SOI (South Oscillation Index), Índice Costero El Niño (ICEN).

SOI (South Oscillation Index): ENOS es monitoreada principalmente por el Índice de Oscilación del Sur (SOI, en sus siglas en inglés), esto basado en las diferencias de presión

entre Tahití y Darwin (Australia). El SOI es una expresión matemática de suavizar las fluctuaciones diarias de la presión del aire entre Tahití y Darwin y estandarizar la información.

ONI (Oceanic Niño Index): El Índice del Niño Oceánico (ONI, en sus siglas en inglés), representa la media móvil de tres meses de anomalías consecutivas de la TSM (Figura 6) de la NOAA ERSSTv5 en la región del Niño 3.4 (5N-5S, 170-120W), basado en períodos base cambiante, que consiste en períodos base de 30 años. Estos períodos base de 30 años se utilizan y actualizan para calcular las anomalías para períodos sucesivos de 5 años en el registro histórico.




Figura 6: Índice ONI, desde enero de 1950 hasta diciembre 2021

Fuente: Webb y Magi (2022)

Índice Costero El Niño (ICEN): Después del “Niño 1997/98” la NOAA reconoció la presencia de “El Niño” en los años 2002- 2003, 2004-2005, 2006-2007 y 2009-2010, de los cuales sólo los del 2002-2003 y 2009-2010 afectaron la región Niño 1+2 (frente a la costa norte de Perú).

Ante esta situación, el Comité Multisectorial del Estudio del Fenómeno El Niño (ENFEN), elaboró el “Índice Costero El Niño” (ICEN) (Figura 7), basado en la anomalía de temperatura del mar en la región Niño 1+2, que daría una referencia (aunque imperfecta) para las temperaturas de la costa. Además, debido a que El Niño es un fenómeno con escala de tiempo interanual, se resolvió aplicar una media móvil de 3 meses para reducir las fluctuaciones (ruido) de alta frecuencia. Se decidió también documentar con precisión el procedimiento de cálculo (ver abajo) para que el índice fuera reproducible (ENFEN, 2012).

La fuente de datos para este índice son las TSM absolutas del producto ERSSTv3b de la NOAA para la región Niño 1+2, las cuales se pueden obtener de internet de: <http://www.cpc.ncep.noaa.gov/data/indices/ersst3b.nino.mth.ascii> , y los datos del índice del siguiente enlace: <http://met.igp.gob.pe/datos/icen.txt>.




Figura 7: Índice ICEN, desde enero de 1950 hasta diciembre 2021

Fuente: Takahashi et al (2014)

En la siguiente Tabla 1, se muestra la categorización del índice ICEN).

Tabla 1: Categorías de las anomalías según el ICEN.

Categorías	ICEN
Fría Fuerte	Menor que -1.4
Fría Moderada	Mayor o igual que -1.4 y menor que -1.2
Fría Débil	Mayor o igual que -1.2 y menor que -1.0
Neutras	Mayor o igual que -1.0 y menor o igual que 0.4
Cálida Débil	Mayor que 0.4 y menor o igual que 1.0
Cálida Moderada	Mayor que 1.0 y menor o igual que 1.7
Cálida Fuerte	Mayor que 1.7 y menor o igual que 3.0
Cálida Extraordinaria	Mayor que 3.0

Fuente: ENFEN (2012)

5.2.3. Métodos actuales para pronóstico de ENOS

En la actualidad, los métodos existentes para el pronóstico ENOS se pueden clasificar aproximadamente en dos categorías, modelos dinámicos (basados en predicción numérica del tiempo) y modelos estadísticos (McPhaden et al., 2018; Tang et al., 2018; y Ren et al., 2020;).

Para los primeros, los modelos dinámicos simulan las ecuaciones diferenciales parciales que se basan en las leyes de la física océano – atmósfera numéricamente para predecir ENOS (Barnston et al., 2012). Sin embargo, la mejora de la habilidad de la predicción numérica se ve afectada por muchos factores complicados, como la parametrización de la sub red, el cual requiere mucho tiempo y esfuerzo computacional. Mientras tanto, ENOS no se predice lo suficientemente bien hasta con 6 meses de anticipación debido a la existencia de la llamada barrera de predictibilidad (Duan y Wei, 2013; Goddard et al., 2001; Goddard et al., 2009).

Los modelos estadísticos convencionales analizan los datos relacionados con ENOS desde una perspectiva estadística (Kug et al., 2004), pero estos enfoques carecen de una fuerte capacidad de mapeo no lineal para extraer características inherentes de grandes cantidades de datos.

A menudo, las anomalías se proporcionan directamente en un gráfico o una tabla de datos por los respectivos centros de pronóstico de gran parte del mundo para la región de Niño 3.4. En algunos casos, sin embargo, se otorgan por períodos de 1 mes, o por períodos de 3 meses de una región (o regiones) distinta del Niño 3.4.

El IRI recomienda a los pronosticadores a utilizar el período estándar 1971-2000 como período base, o un período no muy diferente de este para calcular las anomalías de la TSM, en la tabla 2 se muestra los modelos de pronóstico de ENOS más utilizados en la actualidad.

Tabla 2: Modelos de pronósticos ENOS dinámicos y estadísticos dados por IRI

Nº	Modelo	Tipo de modelo	Descripción
1	NASA GMAO	Dinámico	NASA GMAO GEOS-S2S
2	NCEP CFSv2	Dinámico	NOAA Climate Prediction Center NCEP CFSv2
3	JMA	Dinámico	Tokyo Climate Center
4	BCC_CSM11m	Dinámico	Beijing Climate Center SM1.1 Dynamic Model
5	SAUDI KAU	Dinámico	Saudi King Abdulaziz University Climate Center
6	LDEO	Dinámico	Lamont-Doherty Earth Observatory, Columbia University
7	AUS-ACCESS	Dinámico	Australian Community Climate and Earth System Simulator
8	ECMWF	Dinámico	European Centre for Medium-Range Weather Forecasts SEAS5
9	UKMO	Dinámico	UK Met Office GloSea 6
10	KMA SNU	Dinámico	Korean Met Agency SNU
11	IOCAS ICM	Dinámico	Institute of Oceanology, Chinese Academy of Sciences
12	COLA CCSM4	Dinámico	University of Miami
13	MetFRANCE	Dinámico	Meteo France Seasonal Forecast
14	SINTEX-F	Dinámico	Japanese Agency for Marine-Earth Science and Technology
15	CSI-IRI-MM	Dinámico	University of Pretoria, Willem Landman
16	GFDL Spear	Dinámico	NOAA GFDL
17	CMC CANSIP	Dinámico	Government of Canada CanSIPS
18	NTU CODA	Estadístico	Taiwan Computational Oceanography and Dynamics of A-rSea
19	BCC RZDM	Estadístico	Beijing Climate Center RZDM
20	CPCMRKOV	Estadístico	NOAA CPC MARKOV
21	CPC CA	Estadístico	NOAA CPC Canonical Correlation Analysis
22	CSU CLIPR	Estadístico	Colorado State University
23	IAP-NN	Estadístico	Institute of Applied Physics of the Russian Academy of Sciences
24	UCLA TCD	Estadístico	UCLA Theoretical Climate Dynamics
25	CPC CONSOL		Consolidated NINO3.4 Outlook Probability Table

VI. METODOLOGÍA

6.1. TIPO DE INVESTIGACIÓN

El proyecto de investigación corresponde al tipo de investigación descriptiva, longitudinal y prospectiva, por lo que se tratará de solucionar un problema muy frecuente de la variabilidad climática del mundo en lo que respecta al pronóstico de ENOS; utilizando productos de investigaciones básicas como es datos de reanálisis.

6.2. IDENTIFICACIÓN DE VARIABLES

Las variables a usar son las siguientes:

6.2.1. Variables de entrada:

Variables oceánicas: Temperatura superficial del mar, contenido de calor oceánico promedio hasta los 300 metros de profundidad, todo esto en las regiones Niño.

Variables atmosféricas: Vientos meridionales y zonales en las regiones Niño.

6.2.2. Variable de salida:

La variable de salida será las anomalías de la temperatura superficial del mar en las regiones Niño.

6.3. LOCALIZACION Y AREA DE ESTUDIO

La localización y el área de estudio (Figura 8) para nuestra investigación son las siguientes:

Niño 1+2 (0-10S, 90W-80W): La región Niño 1+2, está ubicada en la zona oriental del océano Pacífico, y corresponde a la región costera de América del Sur. Donde El Niño fue reconocido por primera vez por las poblaciones locales.

Niño 3 (5N-5S, 150W-90W): Esta región anteriormente fue el foco principal para monitorear y predecir El Niño, pero con el transcurso del tiempo y mayores investigaciones, los científicos aprendieron que la región clave para las interacciones océano-atmósfera acopladas para la ENOS se encuentra más al oeste (Trenberth, 1997).

Niño 3.4 (5N-5S, 170W-120W): Se puede considerar que las anomalías de la TSM de la región Niño 3.4 se utiliza para observar la evolución de ENOS en el tiempo. Así mismo hoy en día es la principal región de monitoreo y predicción de ENOS para la mayoría de países del planeta.

Niño 4 (5N-5S, 160E-150W): El índice Niño 4 captura anomalías de la TSM en el Pacífico ecuatorial central.

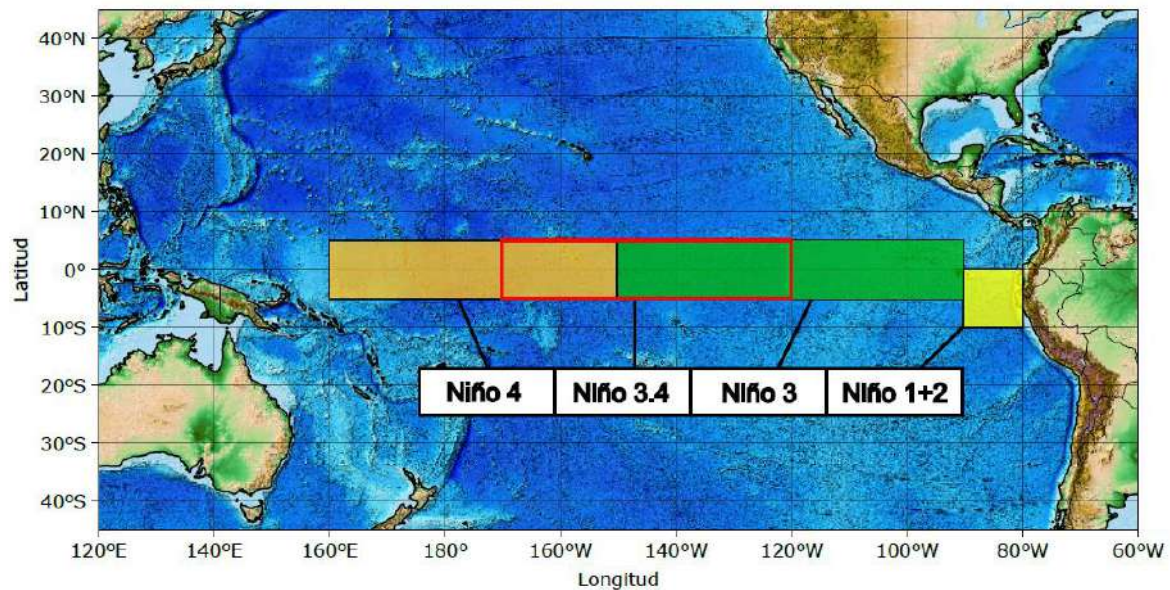


Figura 8: Ubicación espacial de las regiones Niño 1+2, Niño 3, Niño 4 y Niño 3.4 en el pacífico tropical

6.4. PROCEDIMIENTO

6.4.1. Caracterización de los datos climáticos predictores oceánicos y atmosféricos

La caracterización de los datos climáticos se basa en la física de ENOS, por lo cual nos enfocaremos a data de temperatura superficial del mar, contenido de calor oceánico aproximadamente hasta los 300m de profundidad, vientos zonales y meridionales.

a. Obtención y procesamiento de la información oceánica y atmosférica: Esta información será obtenida de la Administración Nacional Oceánica y Atmosférica (NOAA, en sus siglas en inglés), siendo necesario los datos de la TSM, contenido de calor oceánico hasta los 300 metros de profundidad, vientos meridionales y zonal, esto será desde el año 1850 hasta el presente, será valores mensuales de la región Niño del Pacífico tropical. Esta obtención de datos será automatizada mediante lenguajes de programación como Python, Google Earth Engine (GEE) y R.

Posteriormente, se delimita la región de análisis de todas las variables predictoras en estudio, para el análisis exploratorio correspondiente.

b. Exploración e identificación de los datos oceánicos y atmosféricos

Para la elección de los predictores se evalúa mediante el análisis exploratorio de datos usando los mapas espaciales y temporales de la TSM, el contenido de calor hasta los 300 metros de profundidad, y los vientos meridionales y zonales, para identificar distintos eventos y tipos de Niño y Niña anteriormente sucedidos.

6.4.2. Pronosticos ENOS espacial y temporal de las anomalías de la temperatura superficial del mar

Para obtener este objetivo crearemos y diseñaremos la arquitectura de un modelo de inteligencia artificial ayudado del DL con datos de entrada espacio temporal del océano y la atmósfera, mediante el lenguaje de programación Python, usamos Python por su velocidad de procesamiento en comparación con otros lenguajes de programación.

Las anomalías pronosticadas con el modelo elegido se harán en base a los últimos 30 años, tal como recomienda la NOAA. A continuación, se detalla los procedimientos de este pronóstico ENOS.

a. Normalización de los datos climáticos: Los datos espaciales y temporales anteriormente caracterizados, serán normalizados con el objetivo de optimizar (respecto del tiempo) su proceso de cálculo mediante Python.

b. Creación y elección de la arquitectura del modelo de inteligencia artificial: Una vez elaborado el paso anterior se procede a elaborar distintas arquitecturas de inteligencia artificial, con el fin de poder elegir la arquitectura que más se ajuste (mediante métricas estadísticas) a los datos observados.

c. Desnormalización de los datos climáticos: Una vez elegido el modelo óptimo, ahora se desnormaliza con el objetivo de hacer pronósticos del Niño.

d. Entrenamiento (calibración), validación y prueba de los datos: Nuestros datos serán divididos en tres etapas, como se muestra en la Tabla 3.

La etapa de entrenamiento será calibrada con datos de enero de 1871 a diciembre del 2000, en el caso de la etapa de validación se utilizará datos de enero del 2001 a diciembre del 2020

y para la etapa de prueba se utilizará datos de enero del 2021 hasta el presente, para cada una de estas etapas se usarán las métricas más utilizadas de la inteligencia artificial.

Las métricas estadísticas a utilizar son, el error cuadrático medio (MSE, en sus siglas en ingles), la raíz del error cuadrático medio (RMSE, en sus siglas en inglés), el error absoluto medio (MAE, en sus siglas en inglés), la medida del índice de similitud estructural (SSIM, en sus siglas en inglés), el cual es una métrica estadística que se utiliza para medir la similitud entre dos imágenes. Todas estas métricas estadísticas darán mayor eficiencia cuando se aproximen a cero.

Tabla 3: Tabla Rango de datos de la investigación

Entrenamiento (Calibración)	Validación	Prueba (Test)
1871-2000	2001-2020	2021-Presente

e. Pronósticos espacio temporales de ENOS: Se pronosticará espacialmente y temporalmente El Niño, La Niña y la fase neutra de ENOS, iniciando con los datos de entrenamiento (por ejemplo, Niño 1982/83, Niño 1997/98), posteriormente con datos validados (por ejemplo, Niño 2015/16, Niño Costero 2017), y finalmente se hará pronósticos con data de prueba, la data de prueba es data no utilizada por el modelo en ningún momento (por ejemplo, Niño Costero 2022, Niño 2023/24).

Todo esto será procesado mediante el algoritmo de Tensorflow, Keras, y Pytorch, con el uso del lenguaje de programación Python. Se aprovechará los beneficios de Tensorflow, ya que TensorFlow es una biblioteca de código abierto para la computación numérica a gran escala. TensorFlow reúne una serie de modelos y algoritmos de Machine Learning y Deep Learning y los hace útiles mediante una sola plataforma.

De igual manera, Keras es una biblioteca de Redes Neuronales de Código Abierto escrita en Python. Es capaz de ejecutarse sobre TensorFlow. Está especialmente diseñada para posibilitar la experimentación en más o menos poco tiempo con redes de Aprendizaje Profundo.

Así mismo, PyTorch es una biblioteca de aprendizaje automático de código abierto basada en la biblioteca de Torch, utilizado para aplicaciones como visión artificial y procesamiento de lenguajes naturales, principalmente desarrollado por el Laboratorio de Investigación de Inteligencia Artificial de Facebook.

6.4.3. Pronósticos de índices climáticos oceánicos de la región Niño 3.4 y Niño 1+2.

Los índices climáticos, en la actualidad son quizás los índices más utilizados para la evolución y comparación de ENOS en el tiempo, el cual estos nos indican la intensidad y temporalidad de estos eventos (El Niño, La Niña y fase neutra), por lo cual aquí detallamos el proceso de obtención de los índices Niño 3.4 y Niño 1+2.

a. Creación del índice climático Niño 3.4 y Niño 1+2 en base al pronóstico

A partir de los pronósticos espacio temporales realizados en las regiones Niño, se procederá a elaborar los índices Niño 3.4 y Niño 1+2 temporales mediante la metodología dada por la NOAA. Para Niño 3.4, consiste en promediar la temperatura superficial del mar en el área 5N-5S; 170W-120W del océano Pacífico. Y para Niño 1+2, consiste en promediar la temperatura superficial del mar en el área 0-10S, 90W-80W del océano Pacífico.

b. Pronóstico del índice climático Niño 3.4 y Niño 1+2

Una vez creado los índices, se procederá a comparar mediante métricas estadísticas, mencionadas anteriormente, con los datos observados de estos dos índices indicados. Posteriormente se hará pronósticos de los índices Niño 3.4 y Niño 1+2 con datos de prueba (test), mediante el modelo ya creado anteriormente. Valga mencionar que las anomalías de índices se crean a partir de los últimos 30 años, tal como recomienda la NOAA.

6.4.4. Evaluación y comparación del modelo de inteligencia artificial con modelos climáticos globales

Se usará los mejores modelos de pronósticos a nivel mundial y se evaluará de manera espacial y temporal con respecto a la temperatura superficial del mar en las regiones Niño 3.4 y Niño 1+2.

a. Evaluación temporal de la arquitectura del modelo elegido con modelos climáticos del índice Niño 3.4 y Niño 1+2

De la arquitectura elegida se evaluará los pronósticos temporales de las regiones Niño con modelos climáticos globales como se muestra en la Tabla 2. Estas evaluaciones se harán en periodos largos de 6, 9 y 12 meses (pronóstico a largo plazo), y se seleccionará eventos Niño, Niña y fase neutra. Serán evaluadas mediante las métricas estadísticas mencionadas en la sección 6.4.2.

b. Evaluación espacial de la arquitectura del modelo elegido con modelos climáticos en las regiones Niño

De la arquitectura elegida se evaluará los pronósticos espaciales en las regiones Niño con modelos climáticos globales como CFSv2, SINTEX-F y METEO FRANCE. Estas evaluaciones se harán en diferentes meses del año, y se seleccionará eventos Niño, Niña y fase neutra. Serán evaluadas mediante las métricas estadísticas mencionadas en la sección 6.4.2.

Se muestra el modelo conceptual preliminar del modelo de pronóstico ENOS en las regiones Niño (Figura 9).

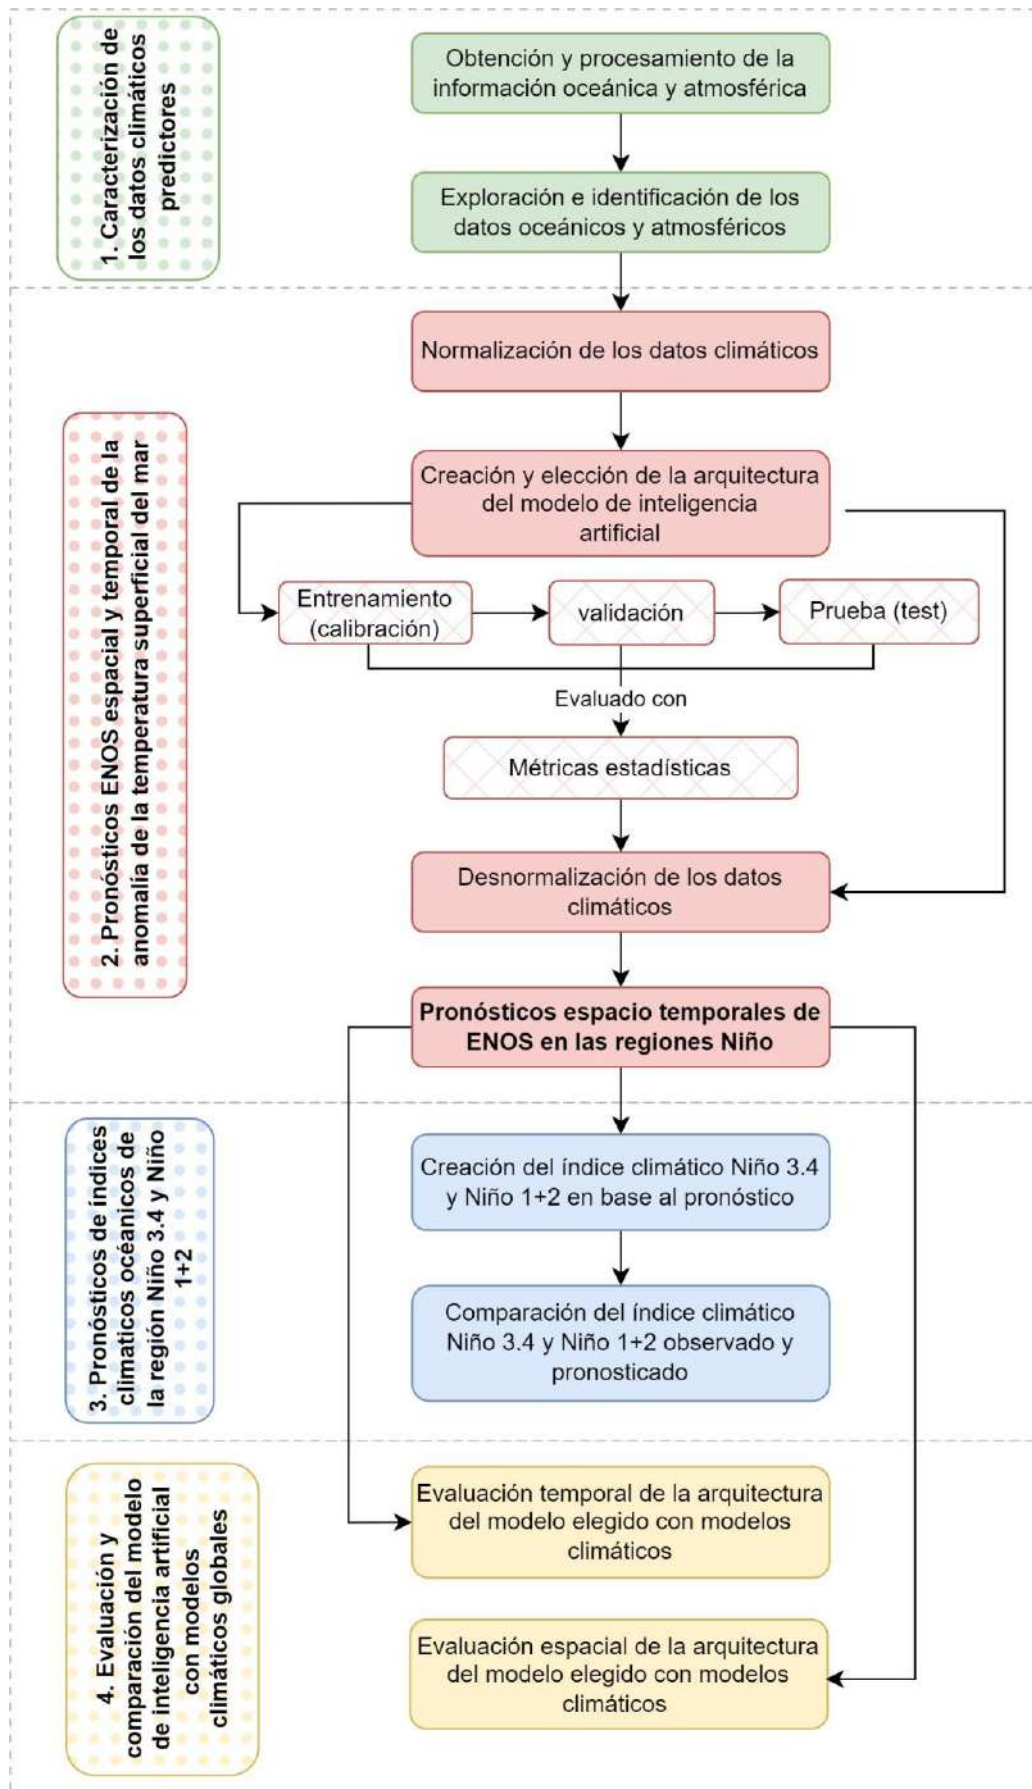


Figura 9: Modelo conceptual preliminar para el pronóstico ENOS

VII. CRONOGRAMA

La duración del proyecto de tesis, se pretende realizar en un periodo de once meses, el mismo se describe de manera detallada en la Tabla 4.

Tabla 4: Cronograma del desarrollo de la tesis

[illegible]

VIII. PRESUPUESTO

El presupuesto del proyecto de tesis a realizarse asciende a la suma de ciento diez mil trescientos cincuenta y cinco con 00/100 nuevos soles (S/.110,355.00), en la Tabla 5 se describe detalladamente el presupuesto para desarrollar el presente proyecto de investigación.

Tabla 5: Presupuesto del proyecto de tesis

	N°	DESCRIPCIÓN	UND.	CANT.	COSTO UNITARIO S/.	COSTO PARCIAL S/.	FUENTE DE FINANCIAMIENTO
RECURSOS HUMANOS	1	RESPONSABLE DE LA INVESTIGACIÓN	MES	24.00	2,500.00	60,000.00	Investigador
	2	ESPECIALISTA EN ESTADÍSTICA	MES	2.00	2,000.00	4,000.00	Investigador
	3	DIGITALIZADOR DE PROGRAMA LATEX	MES	1.00	2,000.00	2,000.00	Investigador
	4	ASISTENTE DE GABINETE	MES	2.00	1,000.00	2,000.00	Investigador
EQUIPOS Y BIENES	1	COMPUTADORA DE ALTO RENDIMIENTO	UND	1.00	20,000.00	20,000.00	Investigador
	2	EQUIPO DE IMPRESIÓN	UND	1.00	500.00	500.00	Investigador
	3	MATERIAL DE ESCRITORIO	GLB	1.00	1,500.00	1,500.00	Investigador
	4	OBTENCIÓN DE BIBLIOGRAFÍA	GLB	1.00	1,500.00	1,500.00	Investigador
SERVICIOS	1	SERVICIO DE COMUNICACIÓN	MES	24.00	30.00	720.00	Investigador
	2	SERVICIO DE INTERNET	MES	24.00	70.00	1,680.00	Investigador
	3	PUBLICACIÓN	GLB	1.00	11,000.00	11,000.00	Investigador
	4	IMPRESIÓN Y EMPASTADO DE TESIS	UND	2.00	100.00	200.00	Investigador
SUB TOTAL						105,100.00	
IMPREVISTOS 5%						5,255.00	
TOTAL						110,355.00	

IX. COLABORADORES

- Dr. Eusebio Mercedes Ingol Blanco
- Dr. Eduardo Abraham Chávarri Velarde
- Dr. Jesús Abel Mejía Marcacuzco

X. REFERENCIAS BIBLIOGRÁFICAS

- Barnston, A. G., Tippett, M. K., L'Heureux, M. L., Li, S., y DeWitt, D. G. (2012). Skill of real-time seasonal ENSO model predictions during 2002–11: Is our capability increasing?. *Bulletin of the American Meteorological Society*, 93(5), 631-651. <https://doi.org/10.1175/BAMS-D-11-00111.1>
- Carrillo, C. N. (1892). Hidrografía oceánica. *Bol. Soc. Geogr. Lima*, 1, 72-111.
- Bjerknes, J. (1969). Atmospheric teleconnections from the equatorial Pacific. *Monthly weather review*, 97(3), 163-172. [https://doi.org/10.1175/1520-0493\(1969\)097<0163:ATFTEP>2.3.CO;2](https://doi.org/10.1175/1520-0493(1969)097<0163:ATFTEP>2.3.CO;2)
- Chen, Y., Huang, X., Luo, J. J., Lin, Y., Wright, J. S., Lu, Y., Chen, X., Jiang, H., Lin, P. (2023). Prediction of ENSO using multivariable deep learning. *Atmospheric and Oceanic Science Letters*, 16(4), Article 100350. <https://doi.org/10.1016/j.aosl.2023.100350>
- Chen, D., Cane, M. A., Kaplan, A., Zebiak, S. E., y Huang, D. (2004). Predictability of El Niño over the past 148 years. *Nature*, 428(6984), 733-736. <https://doi.org/10.1038/nature02439>
- Duan, W., y Wei, C. (2013). The ‘spring predictability barrier’ for ENSO predictions and its possible mechanism: results from a fully coupled model. *International Journal of Climatology*, 33(5), 1280-1292. <https://doi.org/10.1002/joc.3513>.
- ENFEN (2012). Definición operacional de los eventos El Niño y La Niña y sus magnitudes en la costa del Perú, *Nota Técnica* https://www.dhn.mil.pe/Archivos/Oceanografia/ENFEN/nota_tecnica/Definicion%20Operacional%20ENFEN_09abr12.pdf.
- Fedorov, A. V., Harper, S. L., Philander, S. G., Winter, B., y Wittenberg, A. (2003). How predictable is El Niño?. *Bulletin of the American Meteorological Society*, 84(7), 911-920. <https://doi.org/10.1175/BAMS-84-7-911>

- Glantz, M., Katz, R., y Nicholls, N. (1991). Teleconnections linking worldwide climate anomalies. *Cambridge University Press*. <http://n2t.net/ark:/85065/d70003bv>
- Geng, H., y Wang, T. (2021). Spatiotemporal model based on deep learning for ENSO forecasts. *Atmosphere*, 12(7), Article 810. <https://doi.org/10.3390/atmos12070810>
- Goddard, L., Mason, S. J., Zebiak, S. E., Ropelewski, C. F., Basher, R., y Cane, M. A. (2001). Current approaches to seasonal to interannual climate predictions. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 21(9), 1111-1152. <https://doi.org/10.1002/joc.636>
- Goddard, L., DeWitt, D. G., y Reynolds, R. W. (2009). Practical implications of uncertainty in observed SSTs. *Geophysical research letters*, 36(9). Article <https://doi.org/10.1029/2009GL037703>.
- Guo, Y., Cao, X., Liu, B., y Peng, K. (2020). El Niño index prediction using deep learning with ensemble empirical mode decomposition. *Symmetry*, 12(6), Article 893. <https://doi.org/10.3390/sym12060893>
- Jonnalagadda, J., y Hashemi, M. (2022). Feature selection and spatial-temporal forecast of oceanic Niño index using deep learning. *International Journal of Software Engineering and Knowledge Engineering*, 32(01), 91-107. <https://doi.org/10.1142/S0218194022500048>
- Kug, J. S., Kang, I. S., Lee, J. Y., y Jhun, J. G. (2004). A statistical approach to Indian Ocean sea surface temperature prediction using a dynamical ENSO prediction. *Geophysical research letters*, 31(9). Article <https://doi.org/10.1029/2003GL019209>.
- McCulloch, W. S., y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133. <https://doi.org/10.1007/BF02478259>.
- McPhaden, M. J. (2018). Understanding and Predicting El Niño and the Southern Oscillation. *New Frontiers in Operational Oceanography*, 653-662. <https://doi.org/10.17125/gov2018.ch23>.

- Organización Meteorológica Mundial (2014). El Niño/Southern Oscillation. *WMO-No. 1145*, ISBN: 978-92-63-11145-6. <https://library.wmo.int/idurl/4/53800>
- Pal, M., Maity, R., Ratnam, J. V., Nonaka, M., y Behera, S. K. (2020). Long-lead prediction of ENSO modoki index using machine learning algorithms. *Scientific reports*, 10(1), Article 365. <https://doi.org/10.1038/s41598-019-57183-3>.
- Philander S. G. (1990). El Niño, La Niña, and the Southern Oscillation. ix+ 293 pp. San Diego, New York, Berkeley, Boston, London, Sydney, Tokyo, Toronto: Academic Press (Harcourt Brace Jovanovich). Price£ 42.50 (hard covers). ISBN 0 12 553235 0. International Geophysics Series Vol. 46. *Geological Magazine*, 127(5), 478-478. <https://doi.org/10.1017/S0016756800015351>
- Rasmusson, E. M., y Carpenter, T. H. (1982). Variations in tropical sea surface temperature and surface wind fields associated with the Southern Oscillation/El Niño. *Monthly Weather Review*, 110(5), 354-384. [https://doi.org/10.1175/1520-0493\(1982\)110%3C0354:VITSST%3E2.0.CO;2](https://doi.org/10.1175/1520-0493(1982)110%3C0354:VITSST%3E2.0.CO;2).
- Ren, H. L., Zheng, F., Luo, J. J., Wang, R., Liu, M., Zhang, W., Zhou, T., y Zhou, G. (2020). A review of research on tropical air-sea interaction, ENSO dynamics, and ENSO prediction in China. *Journal of Meteorological Research*, 34(1), 43-62. <https://doi.org/10.1007/s13351-020-9155-1>.
- Shi, X., y Yeung, D. Y. (2018). Machine learning for spatiotemporal sequence forecasting: A survey. *arXiv preprint arXiv:1808.06865*. <https://doi.org/10.48550/arXiv.1808.06865>
- Samuel A. (1959). Some studies in machine learning using the game of checkers. *IBM J.*, 3(2), 210-229. <https://doi.org/10.1147/rd.33.0210>.
- Singh, P., & Manure, A. (2019). *Learn TensorFlow 2.0: Implement Machine Learning and Deep Learning Models with Python*. Apress. <https://doi.org/10.1007/978-1-4842-5558-2>
- Tang, Y., Zhang, R. H., Liu, T., Duan, W., Yang, D., Zheng, F., Ren, H., Lian T., Gao C., Chen, D., y Mu, M. (2018). Progress in ENSO prediction and predictability study. *National Science Review*, 5(6), 826-839. <https://doi.org/10.1093/nsr/nwy105>

- Takahashi, K., Mosquera, K. y Reupo, J. (2014). El Índice Costero El Niño (ICEN): historia y actualización. *Boletín técnico: Generación de modelos climáticos para el pronóstico de la ocurrencia del Fenómeno El Niño*, Instituto Geofísico del Perú, 1(2), 8-9. <https://repositorio.igp.gob.pe/handle/20.500.12816/4639>
- Takahashi, K., Mosquera, K., Pareja, D., Reupo, J. y Aparco, J. (2014). Monitoreo del Pacífico ecuatorial. *Boletín técnico: Generación de modelos climáticos para el pronóstico de la ocurrencia del Fenómeno El Niño*, Instituto Geofísico del Perú, 1(3), 8-10. <https://repositorio.igp.gob.pe/handle/20.500.12816/4640>
- Trenberth, K. E. (1997). The definition of el nino. *Bulletin of the American Meteorological Society*, 78(12), 2771-2778. [https://doi.org/10.1175/1520-0477\(1997\)078%3C2771:TDOENO%3E2.0.CO;2](https://doi.org/10.1175/1520-0477(1997)078%3C2771:TDOENO%3E2.0.CO;2).
- Yan, J., Mu, L., Wang, L., Ranjan, R., y Zomaya, A. Y. (2020). Temporal convolutional networks for the advance prediction of ENSO. *Scientific reports*, 10(1), Article 8055. <https://doi.org/10.1038/s41598-020-65070-5>
- Yeh, S. W., Kug, J. S., Dewitte, B., Kwon, M. H., Kirtman, B. P., y Jin, F. F. (2009). El Niño in a changing climate. *Nature*, 461(7263), 511-514. <https://doi.org/10.1038/nature08316>
- Wallace, J. M., y Gutzler, D. S. (1981). Teleconnections in the geopotential height field during the Northern Hemisphere winter. *Monthly weather review*, 109(4), 784-812. [https://doi.org/10.1175/1520-0493\(1981\)109<0784:TITGHF>2.0.CO;2](https://doi.org/10.1175/1520-0493(1981)109<0784:TITGHF>2.0.CO;2)
- Wang, H., Hu, S., y Li, X. (2023). An Interpretable Deep Learning ENSO Forecasting Model. *Ocean-Land-Atmosphere Research*, 2, Article 0012. <https://doi.org/10.34133/olar.0012>
- Wang, Y., Zhang, Y., y Wang, G. G. (2023). Forecasting ENSO using convolutional LSTM network with improved attention mechanism and models recombined by genetic algorithm in CMIP5/6. *Information Sciences*, 642, Article 119106. <https://doi.org/10.1016/j.ins.2023.119106>.
- Webb, E. J., y Magi, B. I. (2022). The Ensemble Oceanic Niño Index. *International Journal of Climatology*, 42(10), 5321-5341. <https://doi.org/10.1002/joc.7535>.