

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

ESCUELA DE POSGRADO

MAESTRÍA EN RECURSOS HÍDRICOS



**“PRONÓSTICO ENOS EN LAS REGIONES NIÑO 3.4 Y NIÑO 1+2,
UTILIZANDO REDES NEURONALES PROFUNDAS CON
SECUENCIAS ESPACIO TEMPORALES”**

Presentada por:

KENNEDY RICHARD GOMEZ TUNQUE

**TESIS PARA OPTAR EL GRADO DE
MAGISTER SCIENTIAE EN RECURSOS HÍDRICOS**

Lima - Perú

2023

Document Information

Analyzed document	tesis-GOMEZ-TUNQUE_230922.pdf (D144724455)
Submitted	2022-09-23 22:56:00
Submitted by	Eusebio Ingol Blanco
Submitter email	eingol@lamolina.edu.pe
Similarity	1%
Analysis address	eingol.unalm@analysis.arkund.com

Sources included in the report

SA	1578276559_59__Tarea_ONI_1.pdf Document 1578276559_59__Tarea_ONI_1.pdf (D61880421)	
W	URL: https://www.cenepred.gob.pe/web/wp-content/uploads/Escenarios/2018/NowCasting/2017/11.Noviembre/07.11.2017/1000H/Nivel%2004/DESCARGA_REQUERIMIENTO_SOLIS/2013/EscenarioRiesgos%20LaNina.pdf Fetched: 2022-08-24 23:40:41	
SA	Rodriguez_Antonio_Tesis_Maestría_ESPOL_18abril17.docx Document Rodriguez_Antonio_Tesis_Maestría_ESPOL_18abril17.docx (D27828934)	
SA	Conductores climáticos y no climáticos_prueba_arkund_traducción_google.docx Document Conductores climáticos y no climáticos_prueba_arkund_traducción_google.docx (D14236810)	
SA	1590718392_Tesis_MECP_NestorMontaño_20200510.docx Document 1590718392_Tesis_MECP_NestorMontaño_20200510.docx (D73184958)	
SA	Tesis (4).pdf Document Tesis (4).pdf (D79525146)	
SA	Universidad Nacional Agraria La Molina / cavalcanti-cardenas-kenyi-glicerio.pdf Document cavalcanti-cardenas-kenyi-glicerio.pdf (D132746899) Submitted by: kcavalcanti@lamolina.edu.pe Receiver: kcavalcanti.unalm@analysis.arkund.com	
SA	Universidad Nacional Agraria La Molina / PROYECTO DE TESIS_CRISTIAN_MIÑOPE.pdf Document PROYECTO DE TESIS_CRISTIAN_MIÑOPE.pdf (D142777809) Submitted by: alexisibanez@lamolina.edu.pe Receiver: alexisibanez.unalm@analysis.arkund.com	

Entire Document

UNIVERSIDAD NACIONAL AGRARIA LA MOLINA ESCUELA DE POSGRADO MAESTRÍA EN RECURSOS HÍDRICOS PRONÓSTICO ENOS EN LAS REGIONES NIÑO 3.4 Y NIÑO 1+2, UTILIZANDO REDES NEURONALES PROFUNDAS CON SECUENCIAS ESPACIO TEMPORALES. Presentada por: KENNEDY RICHARD GOMEZ TUNQUE

TESIS PARA OPTAR EL GRADO DE MAESTRO MAGISTER SCIENTIAE EN RECURSOS HÍDRICOS Lima- Perú 2022

UNIVERSIDAD NACIONAL AGRARIA LA MOLINA ESCUELA DE POSGRADO MAESTRÍA EN RECURSOS HÍDRICOS TESIS PARA OPTAR EL GRADO DE MAESTRO MAGISTER SCIENTIAE PRONÓSTICO ENOS EN LAS REGIONES NIÑO 3.4 Y NIÑO 1+2, UTILIZANDO REDES NEURONALES PROFUNDAS CON SECUENCIAS ESPACIO TEMPORALES. Presentada por: KENNEDY RICHARD GOMEZ TUNQUE Sustentada y aprobada ante el siguiente jurado: Mg.Sc. Cayo Leonidas Ramos T. Ph.D. Eusebio Mercedes Ingol Blanco PRESIDENTE ASESOR Dr. Abel Mejía Marcacuzco Ph.D. Eduardo Chávarri Velarde MIEMBRO MIEMBRO

DEDICATORIA

A mi adorado hijo FABIAN y a mi futura esposa ANALI, a quienes este trabajo nos robó parte de nuestro tiempo. Gracias a ustedes por estar siempre a mi lado y brindarme su apoyo, amor y comprensión de forma incondicional. A mis padres FABIAN Y CIRILA, de quienes recibí el ejemplo de alcanzar siempre las metas propuestas y seguir mis sueños. A mis seres queridos BACILIA E ISABEL que ya no están con nosotros, pero sé que están muy felices de compartir este logro conmigo.

AGRADECIMIENTO En primero lugar, quiero expresar mi agradecimiento al Dr. Eusebio Ingol Blanco asesor de la tesis, por todo su apoyo, por la oportunidad y la confianza. Sus valiosos conocimientos, su enseñanza en temas de mucho interés para mi persona, sus orientaciones y paciencia han sido fundamentales para mi formación profesional. Agradecer de manera especial a todos los docentes que me enseñaron sus valiosos conocimientos en la maestría de Recursos Hídricos de la Universidad Nacional Agraria La Molina. A todos mis amigos del postgrado de la maestría de Recursos Hídricos de la Universidad Nacional Agraria La Molina, ya que compartimos, aprendimos y discutimos temas de ciencias. Y para el final lo más importante, agradecerle a mi familia por su apoyo y sacrificio para esta investigación. A mis padres, que tanto han luchado por mí, gracias padres por hacerme creer en mis sueños, a mis hermanas por la perseverancia y consejos brindados a Analí y mi hijo Fabian, les agradezco por su comprensión, amor y apoyo, ya que han sido vitales para poder alcanzar este logro en nuestras vidas.

ÍNDICE GENERAL I. INTRODUCCIÓN 1 II. REVISIÓN DE LITERATURA 4 2.1. INTELIGENCIA ARTIFICIAL 4 2.1.1. REDES NEURONALES ARTIFICIALES 5 2.1.2. TEORÍA Y ARQUITECTURA DE LAS REDES NEURONALES ARTIFICIALES 5 2.1.3. APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING) 7 2.1.4. Aprendizaje Profundo (Deep Learning) 9 2.1.4.1. Redes Neuronales Convolucionales 9 2.1.4.2. Redes Neuronales Recurrentes 11 2.1.4.3. Red Neuronal ConvLSTM 12 2.1.4.4. Red Neuronal ConvLSTM 13 2.2. EL NIÑO OSCILACIÓN DEL SUR Y EL FENÓMENO DEL NIÑO 15 2.2.1. FENÓMENO DEL NIÑO Y CORRIENTE DEL NIÑO 15 2.2.2. EL NIÑO OSCILACION DE SUR 15 2.2.3. CONDICIÓN DEL ENOS EN EL PACÍFICO TROPICAL 16 2.3. ÍNDICE CLIMÁTICOS ENOS PARA IDENTIFICAR LA VARIABILIDAD CLIMÁTICA 21 2.4. MÉTODOS ACTUALES PARA PRONÓSTICO DE ENOS 26 2.5. MONITOREO DE ENOS EN EL OCEANO PACÍFICO 29 2.5.1. MATRIZ OCEÁNICA DE LA ATMÓSFERA TROPICAL (TAO) 30 2.5.2. EL PROGRAMA ARGO 31 2.6. MÉTRICAS ESTADÍSTICAS PARA EL PRONÓSTICO ENOS 34 2.6.1. MÉTRICAS ESTADÍSTICAS DE PRECISIÓN 34 2.6.1.1. MÉTRICAS ESTADÍSTICAS BASADAS EN CORRELACIÓN 34 2.6.1.2. Métricas estadísticas dependientes de la escala 37 2.6.1.3. Métricas estadísticas dependientes del porcentaje 39 2.7. LA TRANSFORMADA ONDELETA 40 2.7.1. LA TRANSFORMADA ONDELETA CONTINUA (CWT) 41

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

**ESCUELA DE POSGRADO
MAESTRÍA EN RECURSOS HÍDRICOS**

**"PRONÓSTICO ENOS EN LAS REGIONES NIÑO 3.4 Y NIÑO
1+2, UTILIZANDO REDES NEURONALES PROFUNDAS CON
SECUENCIAS ESPACIO TEMPORALES"**

**TESIS PARA OPTAR EL GRADO DE
MAGISTER SCIENTIAE**

Presentada por:

KENNEDY RICHARD GOMEZ TUNQUE

Sustentada y aprobada ante el siguiente jurado:

Mg.Sc. Cayo Leonidas Ramos Taipe

PRESIDENTE

Ph.D. Eusebio Ingol Blanco

ASESOR

Dr. Abel Mejía Marcacuzco

MIEMBRO

Ph.D. Eduardo Chávarri Velarde

MIEMBRO

DEDICATORIA

A mi adorado hijo FABIAN y a mi futura esposa ANALI, a quienes este trabajo nos robó parte de nuestro tiempo. Gracias a ustedes por estar siempre a mi lado y brindarme su apoyo, amor y comprensión de forma incondicional.

A mis padres FABIAN Y CIRILA, de quienes recibí el ejemplo de alcanzar siempre las metas propuestas y seguir mis sueños.

A mis seres queridos BACILIA E ISABEL que ya no están con nosotros, pero sé que están muy felices de compartir este logro conmigo.

AGRADECIMIENTOS

En primero lugar, quiero expresar mi agradecimiento al Dr. Eusebio Ingol Blanco asesor de la tesis, por todo su apoyo, por la oportunidad y la confianza. Sus valiosos conocimientos, su enseñanza en temas de mucho interés para mi persona, sus orientaciones y paciencia han sido fundamentales para mi formación profesional.

Agradecer a los miembros del jurado que evaluaron la tesis: Mg.Sc. Cayo Ramos, Dr. Abel Mejía y Ph.D. Eduardo Chávarri, por sus valiosas observaciones y recomendaciones.

Agradecer de manera especial a todos los docentes que me enseñaron sus valiosos conocimientos en la maestría de Recursos Hídricos de la Universidad Nacional Agraria La Molina.

A todos mis amigos del postgrado de la maestría de Recursos Hídricos de la Universidad Nacional Agraria La Molina, ya que compartimos, aprendimos y discutimos temas de ciencias.

Y para el final lo más importante, agradecerle a mi familia todo su apoyo y sacrificio para esta investigación. A mis padres, que tanto han luchado por mí, gracias padres por hacerme creer en mis sueños, a mis hermanas por la perseverancia y consejos brindados, a Analí y mi hijo Fabian, les agradezco por su comprensión, amor y apoyo, ya que han sido vitales para poder alcanzar este logro en nuestras vidas.

ÍNDICE GENERAL

I	INTRODUCCIÓN	1
II	REVISIÓN DE LITERATURA	4
2.1	INTELIGENCIA ARTIFICIAL	4
2.1.1	Redes neuronales artificiales	4
2.1.2	Teoría y arquitectura de las redes neuronales artificiales	6
2.1.3	Aprendizaje automático (<i>Machine learning</i>)	7
2.1.4	Aprendizaje profundo (<i>Deep learning</i>)	9
2.1.4.1	Redes neuronales convolucionales	10
2.1.4.1.1	Arquitectura de un CNN	10
2.1.4.2	Redes neuronales recurrentes	12
2.1.4.2.1	Red Neuronal de Memoria a Corto y Largo Plazo	13
2.1.4.3	Red neuronal ConvLSTM	14
2.2	EL NIÑO OSCILACIÓN DEL SUR Y EL FENÓMENO DEL NIÑO	16
2.2.1	Fenómeno del Niño y corriente del Niño	16
2.2.2	El Niño Oscilación del Sur	16
2.2.3	Condición del ENOS en el pacífico tropical	17
2.2.4	ENOS y las teleconexiones atmosféricas y su relación con la variabilidad climática	21
2.3	ÍNDICES CLIMÁTICOS ENOS PARA IDENTIFICAR LA VARIABILIDAD CLIMÁTICA	23
2.4	MÉTODOS ACTUALES PARA PRONÓSTICO DE ENOS	28
2.5	MONITOREO DE ENOS EN EL OCÉANO PACÍFICO	32
2.5.1	Matriz oceánica de la atmósfera tropical (TAO)	32
2.5.2	El programa ARGO	33
2.6	MÉTRICAS ESTADÍSTICAS PARA EL PRONÓSTICOS ENOS	36

2.6.1	Métricas estadísticas de precisión	36
2.6.1.1	Métricas estadísticas basadas en correlación	36
2.6.1.2	Métricas estadísticas dependientes de la escala	38
2.6.1.3	Métricas estadísticas dependientes del porcentaje	41
2.7	LA TRANSFORMADA ONDELETA	42
2.7.1	La transformada ondeleta continua (CWT)	43
2.7.2	Transformada ondeleta coherencia (WTC)	43
III	MATERIALES Y MÉTODOS	45
3.1	DESCRIPCIÓN DEL ÁREA DE ESTUDIO	45
3.2	DATOS	46
3.2.1	Datos de la TSM grillada en las regiones Niño	47
3.2.2	Datos de los índices de anomalías de la TSM en las regiones Niño	48
3.3	METODOLOGÍA	49
3.3.1	Pre procesamiento de datos de la TSM	49
3.3.1.1	Recolección de datos de mapas cuadrículados espaciales temporales de la TSM del pacífico tropical	49
3.3.1.2	Normalización de la TSM en el área de estudio	50
3.3.2	Creación y elección de la arquitectura del modelo de red neuronal profunda CONVLSTM	50
3.3.3	Entrenamiento (calibración) y validación de datos de la TSM	51
3.3.4	Modelo de pronóstico de la TSM espacio temporal	52
3.3.4.1	Pronóstico y evaluación de la TSM y anomalías de la TSM espacio temporal con El Niño Extraordinario de 1982/1983 y 1997/98.	52
3.3.4.2	Pronóstico de la TSM y anomalías de la TSM espacio temporal de eventos El Niño en diferentes horizontes de tiempo en etapa de test	52
IV	RESULTADOS Y DISCUSIÓN	57
4.1	DESCRIPCIÓN Y EXPLORACIÓN DE DATOS	57
4.1.1	Exploración y análisis de datos de eventos ENOS	57

4.1.2	Exploración de datos temporal y espacial (longitud y latitud promedio) en la región de estudio (latitud 10°S–10°N y longitud 140°E–80°W)	65
4.1.3	Exploración de datos espectral temporal de los índices de la ATSM del Niño 3.4 Y Niño 1+2	69
4.2	MODELO DE RED NEURONAL PROFUNDA, QUE INTEGRA LA MEMORIA CONVOLUCIONAL A CORTO Y LARGO PLAZO (CONVLSTM)	71
4.3	MODELO DE RED NEURONAL PROFUNDA PARA PRONÓSTICOS EL NIÑO EXTRAORDINARIO 1982/83 Y 1997/98	75
4.4	PRONÓSTICO DE ANOMALÍAS DE LA TSM DE LAS REGIONES NIÑO 3.4 Y NIÑO 1+2, MEDIANTE LA RED NEURONAL PROFUNDA	81
4.4.1	Pronóstico de las ATSM y TSM del niño extraordinario 2015/16	81
4.4.2	Pronóstico de las ATSM y TSM del Niño costero 2017	98
4.4.3	Pronóstico de la ATSM y TSM de la Niña 2022	108
4.5	COMPARACIÓN Y EVALUACIÓN DEL MODELO DE RED NEURONAL CON MODELOS CLIMÁTICOS DINÁMICOS Y ESTADÍSTICOS A NIVEL GLOBAL	117
4.5.1	Discusión de pronóstico globales y el modelo ConvLSTM, en la región Niño 3.4	117
4.5.1.1	Año 2015, pronóstico estacional iniciando en julio (JJA) del 2015	117
4.5.1.2	Año 2016, pronóstico estacional iniciando en enero (DJF) del 2016	121
4.5.1.3	Año 2016/17 pronósticos estacional iniciando en noviembre (OND) del 2016	124
4.5.1.4	Año 2022 pronósticos estacional iniciando en enero (DJF) del 2022	128
4.5.2	Discusión de pronóstico globales y el modelo ConvLSTM, en la región Niño 1+2	132
4.5.2.1	Año 2016/17, pronóstico estacional iniciando en noviembre (OND) del 2016	132

4.5.2.2	Año 2022, pronóstico estacional iniciando en enero (DJF) del 2022	134
4.5.3	Inspección de modelos de pronósticos grillados a nivel global	135
4.5.3.1	Modelos de pronósticos grillados a nivel global año 2016	135
4.5.3.2	Modelos de pronósticos grillados a nivel global año 2017	139
4.5.3.3	Modelos de pronósticos grillados a nivel global año 2022	143
4.6	DISCUSIÓN DE RESULTADOS	145
V	CONCLUSIONES	149
VI	RECOMENDACIONES	154
VII	REFERENCIAS BIBLIOGRÁFICAS	156
VIII	ANEXOS	165

ÍNDICE DE FIGURAS

Figura 1	El aprendizaje profundo es un subconjunto de las redes neuronales, que es un subconjunto del aprendizaje automático, que es un subconjunto de la inteligencia artificial	5
Figura 2	Neurona biológica del cerebro humano	5
Figura 3	Arquitectura de una Red Neuronal Artificial	7
Figura 4	Categorización del aprendizaje automático del aprendizaje supervisado y no supervisado	9
Figura 5	Arquitectura de una Red Neuronal Artificial Simple y de una Red Neuronal de Aprendizaje Profundo	9
Figura 6	Ejemplo de la arquitectura de una CNN	11
Figura 7	Bucle de una RNN	12
Figura 8	La red neuronal a) RNN, b) LSTM y c) GRU	13
Figura 9	Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan	14
Figura 10	Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan	14
Figura 11	Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan	15
Figura 12	Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones Normales	18
Figura 13	Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones El Niño	19

Figura 14	Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones La Niña	20
Figura 15	El perfil de la TSM y de la temperatura del agua profunda en el Océano Pacífico Ecuatorial, se ilustra cómo cambia la capa superior del océano durante la transición de la condición normal (enero 1997) a condición El Niño (noviembre de 1997) a la condición de desarrollo de La Niña (marzo del 1998)	20
Figura 16	Los efectos de El Niño en el mundo descrito a través de teleconexiones	22
Figura 17	Los efectos de La Niña en el mundo descrito a través de teleconexiones	22
Figura 18	Ubicación geográfica de algunos de los índices más utilizados	23
Figura 19	Ubicación de las localidades en las que se mide la presión atmosférica. El signo de la diferencia entre los registros de Tahití y Darwin (Australia) indica la presencia de El Niño o La Niña	24
Figura 20	Índice SOI de la región Niño 3.4	24
Figura 21	Índice ONI	25
Figura 22	Promedio de la TSM en la región Niño 3.4, con periodo base cada 30 años, es utilizada como base de datos para la generación del Índice ONI	25
Figura 23	Índice ICEN	26
Figura 24	Índices E y C a nivel espacial en el pacífico tropical	28
Figura 25	Modelos de predicción IRI para ENOS en la región Niño 3.4 con respecto a las ATSM para el pronóstico de abril del 2014 a enero del 2016 de modelos dinámicos y estadísticos	30
Figura 26	Mapa de ubicación de las Boyas de TAO/TRITON en el Océano Pacífico	33
Figura 27	Esquema del modelo de boya ATLAS de próxima generación	34
Figura 28	Mapa mundial de ubicación de los flotadores ARGO en el océano global	35
Figura 29	Esquematzación de perfil del flotador ARGO a distintas profundidades en el océano	35
Figura 30	Rango de correlación de r	38
Figura 31	Ubicación espacial de las regiones Niño 1+2, Niño 3, Niño 4 y Niño 3.4 en el Pacífico Tropical	46

Figura 32	Producto ERSSTv5 NOAA-TSM en proyecciones Pseudo cilíndricas (Robinson). Los valores muestran la temperatura media mensual de 1854 – 2022	48
Figura 33	Índices de anomalías de las regiones: Niño 1+2, niño 3, niño 4 y niño 3.4 en el pacífico tropical	49
Figura 34	Rango de datos de esta investigación	52
Figura 35	Esquema metodológico de la investigación	55
Figura 36	Modelo conceptual de la red neuronal profunda utilizada en el pronóstico del ENOS de esta investigación	56
Figura 37	Promedio de la TSM de diciembre a febrero de 1982/83, b) Anomalías de la TSM de diciembre a febrero de 1982/83.	59
Figura 38	a) Promedio de la TSM de diciembre a febrero de 1997/98, b) Anomalías de la TSM de diciembre a febrero de 1997/98	60
Figura 39	a) Promedio de la TSM de noviembre a enero de 1998/99, b) Anomalías de la TSM de noviembre a enero de 1998/99	61
Figura 40	a) Promedio de la TSM de octubre a diciembre del 2010, b) Anomalías de la TSM de octubre a diciembre del 2010	62
Figura 41	a) Promedio de la TSM de abril a junio del 2013, b) Anomalías de la TSM de abril a junio del 2013	63
Figura 42	a) Promedio de la TSM de febrero a abril de 1925, b) Anomalías de la TSM de febrero a abril de 1925	64
Figura 43	Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 1982/83 y b) 1997/98 para Niños Extraordinarios	67
Figura 44	Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 1998/99 y b) 2010/11 para Niña Fuerte en el pacífico central	68
Figura 45	Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 2007/08 y b) 2012/13	68

Figura 46 Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre de 1924/25 a) TSM y b) anomalías de la TSM 69

Figura 47 Análisis espectral de potencia del índice climático Niño 3.4 de 1950 al 2021 a) serie de tiempo de la ATSM, b) Análisis Wavelet tipo Morlet de la serie de tiempo de la ATSM, señales de colores rojo intenso se refieren a una mayor potencia espectral los de color azul menor potencia espectral, las áreas enmarcadas en líneas de color negro representan señales espectrales estadísticamente significantes a un 95 por ciento de confianza. El cono de influencia (colores más nítidos) marca el límite donde el análisis Wavelet es confiable y c) Análisis espectral computado para la serie de tiempo de la ATSM, la línea discontinua de color rojo es la significación estadística del 95 por ciento de confianza 70

Figura 48 Análisis espectral de potencia del índice climático Niño 1+2 de 1950 al 2021 a) serie de tiempo de la ATSM, b) Análisis Wavelet tipo Morlet de la serie de tiempo de la ATSM, señales de colores rojo intenso se refieren a una mayor potencia espectral los de color azul menor potencia espectral, las áreas enmarcadas en líneas de color negro representan señales espectrales estadísticamente significantes a un 95 por ciento de confianza. El cono de influencia (colores más nítidos) marca el límite donde el análisis Wavelet es confiable y c) Análisis espectral computado para la serie de tiempo de la ATSM, la línea discontinua de color rojo es la significación estadística del 95 por ciento de confianza 71

Figura 49 Curva de desempeño del modelo ConvLSTM en 5000 épocas a) Entrenamiento (calibración), b) Validación c) Acercamiento de entrenamiento - validación de 100 a 5000 épocas d) Acercamiento de entrenamiento- validación de 500 a 5000 épocas 74

Figura 50 Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de Octubre a marzo de 1982/83 en etapa de calibración del evento Niño Extraordinario, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W 76

Figura 51	Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de Octubre a marzo de 1997/98 en etapa de calibración del evento Niño Extraordinario, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	79
Figura 52	TSM pronosticado (izquierda) y observado (derecha) de a julio a diciembre 2015 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	83
Figura 53	TSM pronosticado (izquierda) y observado (derecha) de a julio a diciembre 2015 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	84
Figura 54	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	87
Figura 55	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 3.4 (5N-5S, 170W-120W)	88
Figura 56	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 1+2 (0-10S, 90W-80W)	88
Figura 57	TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2016 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	90
Figura 58	Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2016 en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	91
Figura 59	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	94

Figura 60	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 3.4 (5N-5S, 170W-120W)	94
Figura 61	Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 1+2 (0-10S, 90W-80W)	95
Figura 62	Diagrama de longitud-tiempo (Hovmöller) de ATSM pronosticado (izquierda) y observado (derecha) de julio a junio del 2015/16 en etapa de prueba del Niño 2015/16, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W	96
Figura 63	Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de julio a junio del 2015/16 en etapa de prueba Niño 2015/16, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W	97
Figura 64	ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niño Extraordinario 2015/16. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente	98
Figura 65	TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	100
Figura 66	Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W	101

- Figura 67 Diagrama de longitud-tiempo (Hovmöller) de Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del Niño Costero 2017, en el océano Pacífico ecuatorial promedio de latitud 10°S – 10°N y a lo largo de la longitud 140°E – 80°W 104
- Figura 68 Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del Niño Costero 2017, en el océano Pacífico ecuatorial promedio de latitud 10°S – 10°N y a lo largo de la longitud 140°E – 80°W 105
- Figura 69 ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niño Costero 2017. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 106
- Figura 70 Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (noviembre – enero) del 2016/17 mejor correlacionados, en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud 140°E – 80°W 107
- Figura 71 Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (noviembre – enero) del 2016/17 mejor correlacionados, en etapa de prueba del evento Niño Costero 2017 en la región Niño 1+2 (0 - 10S , 90W - 80W) 108
- Figura 72 TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba del evento Niña 2022, en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud 140°E – 80°W 109
- Figura 73 Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud 140°E – 80°W 110
- Figura 74 Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2022 mejor correlacionados, en etapa de prueba del evento La niña 2022, en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud 140°E – 80°W 113

- Figura 75 Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2022 mejor correlacionados, en etapa de prueba del evento La Niña 2022 en la región Niño 3.4 (5N-5S, 170W-120W) 113
- Figura 76 Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres dos meses (enero – febrero) del 2022 mejor correlacionados, en etapa de prueba del evento La Niña 2022 en la región Niño 1+2 (0-10S, 90W-80W) 114
- Figura 77 Diagrama de longitud-tiempo (Hovmöller) de Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W 115
- Figura 78 Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W 115
- Figura 79 ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niña 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 116
- Figura 80 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente 119

Figura 81 Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente

119

Figura 82 Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente

120

Figura 83 Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente

120

Figura 84 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

122

- Figura 85 Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 122
- Figura 86 Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 123
- Figura 87 Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 123
- Figura 88 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 126
- Figura 89 Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 127

- Figura 90 Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 127
- Figura 91 Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 128
- Figura 92 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 129
- Figura 93 Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 130
- Figura 94 Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 131

- Figura 95 Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 132
- Figura 96 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 1+2, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 134
- Figura 97 Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 1+2, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente 135
- Figura 98 ATSM media móvil de enero (DJF) del 2015/16 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W 136
- Figura 99 Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo dinámico CFSv2 a nivel global 137
- Figura 100 Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo dinámico de la Agencia Meteorológica de Japón (SINTEX-F) a nivel global 137
- Figura 101 Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo ConvLSTM a) a nivel global y b) en latitud 10°S – 10°N y longitud 140°E – 80°W del océano Pacífico ecuatorial 138
- Figura 102 ATSM media móvil de diciembre (NDJ) del 2016/17 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W 139
- Figura 103 Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico CFSv2 a nivel global 141

Figura 104	Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico de la Agencia Meteorológica de Japón (SINTEX-F) a nivel global	141
Figura 105	Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico METEO FRANCE a nivel global	142
Figura 106	Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo ConvLSTM a) a nivel global y b) latitud 10°S–10°N y longitud 140°E – 80°W del océano pacifico	142
Figura 107	ATSM media móvil de febrero (JFM) del 2022 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S–10°N y longitud 140°E – 80°W	143
Figura 108	Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo dinámico CFSv2 a nivel global	144
Figura 109	Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo dinámico METEO FRANCE a nivel global	144
Figura 110	Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo ConvLSTM a) a nivel global y b) latitud 10°S–10°N y longitud 140°E – 80°W del océano pacifico	145
Figura 111	Evolución de las ATSM observado de julio del 1982 a junio del 1983 (Niño extraordinario 1982/83), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	165
Figura 112	Evolución de las ATSM observado de enero a diciembre de 1998 (Niño extraordinario 1997/98 e inicio de La Niña 1999), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	166
Figura 113	Evolución de las ATSM observado de julio del 2015 a junio del 2016 (Niño 2015/16), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	166
Figura 114	Evolución de las ATSM observado de julio del 2016 a junio del 2017 (Niño Costero 2017), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.	167

Figura 115 Evolución de las ATSM observado de julio del 2021 a junio del 2022
(La Niña), en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud
 140°E – 80°W .

ÍNDICE DE TABLAS

Tabla 1	Categorías de las anomalías según el ICEN	27
Tabla 2	Modelos de pronósticos ENOS dinámicos y estadísticos dados por IRI	31
Tabla 3	Evaluación del pronóstico de la magnitud de r	37
Tabla 4	Evaluación del pronóstico del valor de $RMSPE$	42
Tabla 5	Evaluación del pronóstico del valor de $MAPE$	42
Tabla 6	Índices climáticos utilizadas en este estudio	47
Tabla 7	Número de capas, dimensiones y número de parámetros del modelo	73
Tabla 8	Estadísticos de pérdida de regresión del modelo de pronóstico con respecto a los valores verdaderos de las ATSM promediados en todas las celdas de la cuadrícula	75
Tabla 9	Métricas estadísticas del Niño Extraordinario 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula en el océano Pacífico ecuatorial ($10^{\circ}S-10^{\circ}N$ y $140^{\circ}E-80^{\circ}W$) de octubre a marzo del 1982/83	78
Tabla 10	Métricas estadísticas de Niño Extraordinario 1982/83 de la región Niño 3.4 ($5N-5S$, $170W-120W$) de octubre a marzo del 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	78
Tabla 11	Métricas estadísticas de Niño Extraordinario 1982/83 de la región Niño 1+2 ($0-10S$, $90W-80W$) de octubre a marzo del 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	78

Tabla 12	Métricas estadísticas del Niño Extraordinario 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) de octubre a marzo del 1997/98	80
Tabla 13	Métricas estadísticas de Niño Extraordinario 1997/98 de la región Niño 3.4 (5N-5S, 170W-120W) de octubre a marzo del 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	80
Tabla 14	Métricas estadísticas de Niño Extraordinario 1997/98 de la región Niño 1+2 (0-10S, 90W-80W) de octubre a marzo del 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	80
Tabla 15	Métricas estadísticas de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)	86
Tabla 16	Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 3.4 (5N-5S, 170W-120W) de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	86
Tabla 17	Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 1+2 (0-10S, 90W-80W) de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	86
Tabla 18	Métricas estadísticas de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)	92
Tabla 19	Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 3.4 (5N-5S, 170W-120W) de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula	92

- Tabla 20 Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 1+2 (0-10S, 90W-80W) de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula 92
- Tabla 21 Métricas estadísticas del Niño Costero 2017 de noviembre a abril 2016/17, del modelo de pronóstico respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) 102
- Tabla 22 Métricas estadísticas de noviembre a abril del 2016/17 de la región Niño 3.4 (5N-5S, 170W-120W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula 102
- Tabla 23 Métricas estadísticas del Niño Costero 2017 de la región Niño 1+2 (0-10S, 90W-80W) de noviembre a abril del 2016/17, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula 102
- Tabla 24 Métricas estadísticas de La Niña 2022 de enero a junio 2022, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) 112
- Tabla 25 Métricas estadísticas de La Niña 2022 de enero a junio de la región Niño 3.4 (5N-5S, 170W-120W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula 112
- Tabla 26 Métricas estadísticas de La Niña 2022 de enero a junio de la región Niño 1+2 (0-10S, 90W-80W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula 112

ÍNDICE DE ANEXOS

Anexo 1 Gráficos de análisis exploratorio y evolución de eventos ENOS (El Niño, La Niña), en distintos periodos	165
---	-----

RESUMEN

El pronóstico de El Niño - Oscilación del Sur (ENOS) es una de las tareas más discutidas y desafiantes de las ciencias oceánicas y atmosféricas, ya que los eventos ENOS observados muestran grandes diferencias entre eventos, en su amplitud, evolución temporal y patrón espacial. El objetivo de esta investigación es proponer un modelo de red neuronal profunda que integra la estructura convolucional de memoria a corto y largo plazo (ConvLSTM) para pronosticar los patrones de la temperatura superficial del mar (TSM) que representan la evolución de ENOS en diferentes horizontes de tiempo y de manera espacial simultáneamente en las regiones Niño 3.4 y Niño 1+2. Para este fin, se utilizaron datos cuadriculados de la TSM del océano Pacífico ecuatorial (latitud 10°S–10°N y longitud 140°E–80°W) para el período de 1854-2022 a nivel mensual. Esta información se obtuvo de la Administración Oceánica y Atmosférica (NOAA). En resumen, la metodología incluye la normalización de la TSM del Pacífico tropical, la creación y selección de la arquitectura del modelo de red neuronal profunda, el entrenamiento, validación y finalmente, el pronóstico y evaluación (prueba) de las anomalías de la TSM espacio temporal de ENOS en las regiones Niño 3.4 y Niño 1+2 con seis meses de anticipación. Los resultados indican un buen desempeño del modelo para El Niño 1982/83 (entrenamiento) y El Niño 1997/98 (validación) en espacio y tiempo, en etapa de prueba se pronosticó espacial y temporalmente para El Niño 2015/16, El Niño Costero 2017 y La Niña 2022. Este desempeño se evaluó utilizando métricas estadísticas de datos observados y pronosticados durante seis meses en el océano Pacífico ecuatorial y posteriormente enfocándonos en la región Niño 3.4 y Niño 1+2, resultando las métricas estadísticas promedio de El Niño 2015/16 (Niño 3.4) de RMSPE a 0.35 por ciento y MAPE a 0.30 por ciento, El Niño Costero 2017 (Niño 1+2) de RMSPE a 2.89 por ciento y MAPE a 2.01 por ciento y La Niña 2022 (Niño 3.4) de RMSPE a 1.24 por ciento y MAPE a 0.83 por ciento. Así mismo, a partir de los pronósticos espacio temporales se comparó con índices climáticos de las regiones Niño 3.4 y Niño 1+2 con modelos globales dinámicos y estadísticos. Por lo tanto, se concluye que se obtiene un mejor pronóstico en la región Niño 3.4 que en la región Niño 1+2; con muy buenos resultados en los tres primeros meses, reduciendo su eficiencia de pronóstico a medida que aumenta el mes de previsión.

Palabras claves: ENOS, ConvLSTM, Niño 3.4, Niño 1+2, espacio temporal.

ABSTRACT

El Niño-Southern Oscillation (ENSO) forecasting is one of the most discussed and challenging tasks in ocean and atmospheric sciences, since the observed ENSO events show large differences between events, in their amplitude, temporal evolution and spatial pattern. The objective of this research is to propose a deep neural network model that integrates the convolutional structure of short and long term memory (ConvLSTM) to forecast sea surface temperature (SST) patterns that represent the evolution of ENSO in different horizons simultaneously in time and space in the Niño 3.4 and Niño 1+2 regions. For this purpose, gridded SST data from the equatorial Pacific Ocean (latitude 10°S–10°N and longitude 140°E–80°W) for the period 1854-2022 at the monthly level were used. This information was obtained from the Oceanic and Atmospheric Administration (NOAA). In summary, the methodology includes the normalization of the tropical Pacific SST, the creation and selection of the deep neural network model architecture, the training, validation, and finally, the forecast and evaluation (test) of the SST anomaly spatiotemporal of ENSO in the Niño 3.4 and Niño 1+2 regions six months in advance. The results indicate a good performance of the model for El Niño 1982/83 (training) and El Niño 1997/98 (validation) in space and time, in the test stage it was forecast spatially and temporally for El Niño 2015/16, El Niño Costero 2017 and La Niña 2022. This performance was evaluated using statistical metrics from observed and forecast data over six months in the equatorial Pacific Ocean and subsequently focusing on the Niño 3.4 and Niño 1+2 region, resulting in average statistical metrics for El Niño 2015/16 (Niño 3.4) of RMSPE at 0.35 percent and MAPE at 0.30 percent, El Niño Costero 2017 (Niño 1+2) of RMSPE at 2.89 percent and MAPE at 2.01 percent and La Niña 2022 (Niño 3.4) of RMSPE at 1.24 percent and MAPE at 0.83 percent. Likewise, based on space-time forecasts, it was compared with climatic indices of the Niño 3.4 and Niño 1+2 regions with global dynamic and statistical models. Therefore, it is concluded that a better forecast is obtained in the Niño 3.4 region than in the Niño 1+2 region; with very good results in the first three months, reducing its forecasting efficiency as the forecast month increases.

Keywords: ENSO, ConvLSTM, Niño 3.4, Niño 1+2, Spatiotemporal.

I. INTRODUCCIÓN

El Niño Oscilación del Sur (ENOS), es el principal impulsor de la variabilidad climática interanual del planeta y a menudo causa una amplia gama de anomalías climáticas (Rasmusson y Carpenter 1982; Philander 1990; Trenberth 1997; McPhaden 2002) de ENOS se han propuestos muchas teorías sobre su origen y evolución (Bjerknes 1969; Neelin *et al.* 1998), sin embargo hasta la actualidad las teorías de ENOS no explica del todo la interacción océano atmósfera en el océano Pacífico Tropical, por lo tanto el pronóstico anticipado de ENOS es siempre un tema científico importante y desafiante.

Dado que aún no se ha establecido una teoría unificada y completa de ENOS, 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 El Niño (ICEN) (ENFEN 2012), basado en datos de la región Niño 1+2, también los índices E y C (Takahashi *et al.* 2011), todo 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; Bauer *et al.* 2015; Capotondi *et al.* 2015), 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 del 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 y Yeung 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 Ecuatorial 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) en una región dada, 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; Ropelewski y Halpert 1987; Glantz *et al.* 1991; Trenberth *et al.* 1998; Mason y Goddard 2001), provocando casi de inmediato lluvias torrenciales, sequías, temperaturas elevadas e incluso descensos bruscos de la temperatura (WMO 2014, 2020). 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; surgiendo como interrogante de investigación, ¿Puede pronosticarse ENOS en las regiones Niño 3.4 y Niño 1+2 usando técnicas de aprendizaje profundo? ¿Cuál es la fiabilidad de esta técnica en relación a los modelos dinámicos y estadísticos globales? Es por eso, que el presente trabajo tiene como objetivo proponer un modelo de red neuronal profunda que integra la memoria convolucional a corto y largo plazo (ConvLSTM), para pronosticar ENOS en diferentes horizontes de tiempo (a largo plazo) con secuencias espacio temporales simultaneas en regiones Niño 3.4 y Niño 1+2.

Con ello también se persigue los siguientes objetivos específicos:

- Proponer un modelo de red neuronal profunda, que integra la memoria convolucional a corto y largo plazo (ConvLSTM).
- Verificar el modelo de red neuronal profunda para pronósticos El Niño extraordinario.

- Calcular y pronosticar anomalías de la temperatura superficial del mar de las regiones Niño 3.4 y Niño 1+2, mediante la red neuronal profunda.
- Comparar y evaluar el modelo de red neuronal profunda con modelos dinámicos y estadísticos globales.

En esta investigación se hizo un intento exitoso de utilizar técnicas de aprendizaje profundo usando el modelo ConvLSTM, con el fin de proporcionar la evolución de ENOS espacio temporal y mejorar la habilidad de pronóstico de ENOS también espacio temporal con seis meses de anticipación, en función de mapas grillados de la TSM y ATSM en el pacífico ecuatorial (latitud 10°S–10°N y longitud 140°E–80°W) y específicamente en regiones Niño 3.4 y Niño 1+2.

II. REVISIÓN DE LITERATURA

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 se explica los conceptos y demás conocimientos fundamentales necesarios para el desarrollo de la investigación respecto de la IA.

Los términos de IA, Aprendizaje Automático (*ML*, en sus siglas en inglés), Redes Neuronales (*NN*, en sus siglas en inglés) y Aprendizaje Profundo (*DL*, en sus siglas en inglés) a menudo se usan indistintamente en el pronóstico y clasificación de datos. Si bien no existen definiciones estándar acordadas por la comunidad científica, los siguientes términos son comunes y se relacionan en la Figura 1.

La IA es cualquier programa o sistema que puede aprender, actuar o adaptarse. La reciente popularidad de la IA proviene de los avances en los algoritmos de ML, específicamente en DL. Un modelo de ML es un programa que aprende una función de los datos de entrada (o las características extraídas de los datos de entrada) a una salida deseada.

2.1.1. Redes neuronales artificiales

McCulloch y Pitts (1943) propusieron un modelo muy simple de la neurona biológica Figura 2, 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, se demostró que incluso con un modelo tan simplificado es posible construir una red de neuronas artificiales que calcula cualquier proposición lógica que se desee.




Figura 1: El aprendizaje profundo es un subconjunto de las redes neuronales, que es un subconjunto del aprendizaje automático, que es un subconjunto de la inteligencia artificial

Fuente: Rodriguez (2020)

En 1958 Franz Rosenblatt propuso el perceptrón, la unidad más básica de procesamiento de las Redes Neuronales, y que impulsó el estudio e investigación de las RNA (Rosenblatt 1958).




Figura 2: Neurona biológica del cerebro humano

Fuente: Baillot (2018)

2.1.2. Teoría y arquitectura de las redes neuronales artificiales

Las RNA, generalmente se componen de funciones no lineales simples, llamadas capas, apiladas para representar funciones o asignaciones complejas. El apilamiento de múltiples funciones lineales da como resultado una función lineal que se puede representar con una capa y anularía el beneficio de las asignaciones de múltiples capas. Por lo tanto, la necesidad de funciones no lineales.

Las RNA intentan imitar el cerebro en su nivel más básico, es decir, el de la neurona Figura 2. Una neurona artificial tiene una estructura similar a la de una neurona humana y comprende las siguientes secciones (Figura 3):

Capa de entrada: Esta capa es similar a las dendritas y recibe información de otras redes / neuronas.

Capa de suma ponderada o regla de entrada: Esta capa funciona como el soma de las neuronas. Agrega la señal de entrada recibida.

Capa o función de activación: Esta capa también es similar a un soma, y toma la información agregada y dispara una señal solo si la entrada agregada cruza un cierto valor de umbral. De lo contrario, no dispara.

Capa de salida: Esta capa es similar a los terminales de axón en que puede estar conectada a otras neuronas/redes o actuar como una capa de salida final (para pronósticos).

En la Figura 3 $X_1, X_2, X_3, \dots, X_n$ son las entradas alimentadas a la red neuronal. $W_1, W_2, W_3, \dots, W_n$ son los pesos asociados con las entradas e Y_p es el pronóstico final. Se pueden usar muchas funciones de activación en la capa de activación para convertir todos los detalles lineales producidos en la entrada y hacer que la capa de suma no sea lineal. Esto ayuda a adquirir más detalles sobre los datos de entrada que no serían posibles si se tratara de una función lineal. Por tanto, la capa de activación juega un papel importante en las predicciones. Algunos de los tipos de funciones de activación más familiares son sigmoide, ReLU y softmax.

Las entradas se enviarán a cada una de las neuronas de la capa oculta, multiplicando cada valor de entrada con un peso (W) y sumándolos con un valor de sesgo (b).

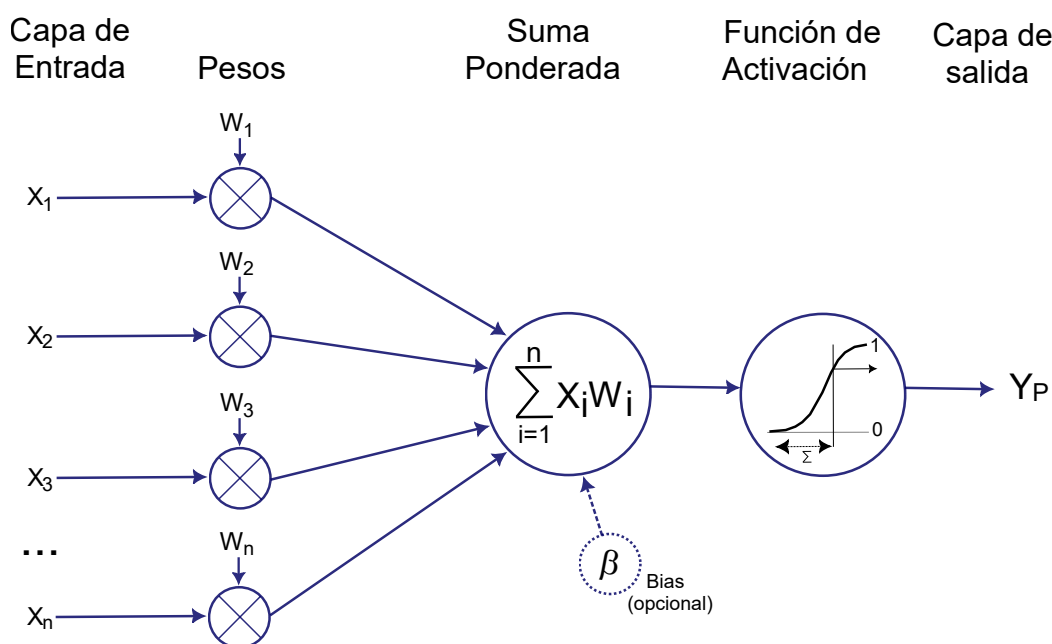


Figura 3: Arquitectura de una Red Neuronal Artificial

Fuente: Elaboración Propia

2.1.3. Aprendizaje automático (*Machine learning*)

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. Para comprender mejor el ML de manera inteligente, considérese las siguientes

formas de categorizarla.

Categorización basada en la cantidad de supervisión humana: Aprendizaje supervisado, Aprendizaje no supervisado, Aprendizaje semi supervisado, Aprendizaje por refuerzo.

Categorización basada en la disponibilidad de datos: Aprendizaje por lotes, Aprendizaje en línea.

Las categorizaciones mencionadas anteriormente nos brindan una visión abstracta de cómo se pueden organizar, comprender y utilizar los algoritmos de ML. La forma más común de categorizarlos es en algoritmos de aprendizaje supervisados y no supervisados (Figura 4). Se detalla un poco más sobre estas dos categorías.

Aprendizaje supervisado: esta clase de aprendizaje implica una alta supervisión humana. Los algoritmos bajo aprendizaje supervisado utilizan los datos de entrenamiento y los resultados asociados para aprender un mapeo entre los dos y aplicar lo mismo en datos no vistos. La clasificación y la regresión son dos tipos principales de algoritmos de aprendizaje supervisado.

Aprendizaje no supervisado: esta clase de algoritmos intenta aprender estructuras, patrones y relaciones latentes inherentes a partir de los datos de entrada sin ninguna salida/etiqueta asociada (supervisión humana). La agrupación en clústeres, la reducción de la dimensionalidad, la minería de reglas de asociación, etc., son algunos de los principales tipos de algoritmos de aprendizaje no supervisados.



Figura 4: Categorización del aprendizaje automático del aprendizaje supervisado y no supervisado

2.1.4. Aprendizaje profundo (*Deep learning*)

El aprendizaje profundo (DL, en sus siglas en inglés) es un subconjunto del aprendizaje automático, y trata de un conjunto de algoritmos y técnicas que tienen como fin el aprendizaje automático. Los modelos DL son RNA de más de tres capas y son diferenciables de extremo a extremo (Figura 5).

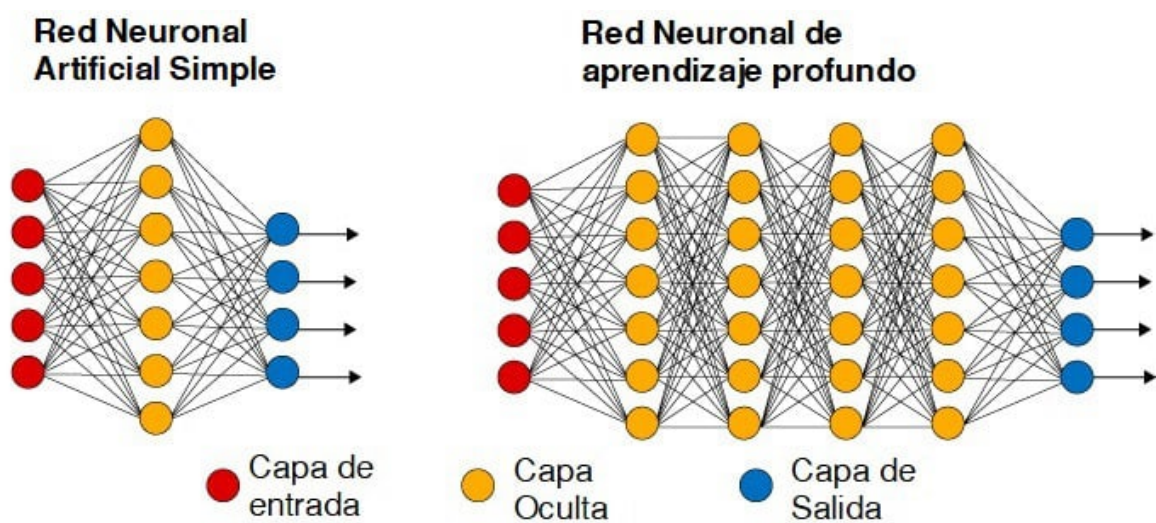


Figura 5: Arquitectura de una Red Neuronal Artificial Simple y de una Red Neuronal de Aprendizaje Profundo

Se describe en esta sección 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.

2.1.4.1. Redes neuronales convolucionales

La Red Neuronal Convolucional (CNN) ha demostrado un rendimiento excelente en muchos problemas de visión artificial y aprendizaje automático. Se han publicado muchos artículos sólidos sobre este tema (Wu 2017).

La arquitectura del CNN (Figura 6), se especializa en procesar datos de topología en forma de cuadrícula, como imágenes, está generalmente compuesta por capas convolucionales, seguidas de capas de agrupamiento. Al final de la arquitectura cuenta capas completamente conectadas que sirven para la clasificación de las imágenes que están siendo procesadas. Constan de tres capas distintas.

2.1.4.1.1. Arquitectura de un CNN

Se muestra los procedimientos en cada capa de un CNN.

Entrada: una matriz de valores de píxeles en forma de ancho, alto y canales.

Convolución: el propósito final de esta capa es recibir un mapa de características. Por lo general, se comienza con una cantidad baja de filtros para la detección de características de bajo nivel. Cuanto más se profundiza en la CNN, más filtros (generalmente también son más pequeños) se usa para detectar características de alto nivel.

Capa de agrupación: similar a la capa convolucional, la capa de agrupación es responsable de reducir el tamaño espacial de la convolución. Esto es para disminuir la potencia computacional requerida para procesar los datos a través de la reducción de la dimensionalidad. Además, es útil para extraer características dominantes que son invariantes rotacionales y posicionales, manteniendo así el proceso de entrenamiento efectivo del

modelo. Hay dos tipos de Pooling: Max Pooling y Average Pooling.

Max Pooling devuelve el valor máximo de la parte de la imagen cubierta por el Kernel. Por otro lado, Average Pooling devuelve el promedio de todos los valores de la porción de la imagen cubierta por el Kernel.

Activación: sin entrar en más detalles, se utiliza la función de activación de ReLU que devuelve 0 para cada valor negativo en la imagen de entrada, mientras que devuelve el mismo valor para cada valor positivo.

Capa totalmente conectada (capa FC): en una capa totalmente conectada, se aplanan la salida de la última capa de convolución y se conecta cada nodo de la capa actual con el otro nodo de la siguiente capa. Las neuronas en una capa completamente conectada tienen conexiones completas con todas las activaciones en la capa anterior, como se ve en las redes neuronales regulares y funcionan de manera similar.

La última capa de nuestra CNN calculará las puntuaciones de probabilidad de clase, lo que dará como resultado un volumen de tamaño 1 x 1 x número de clases.

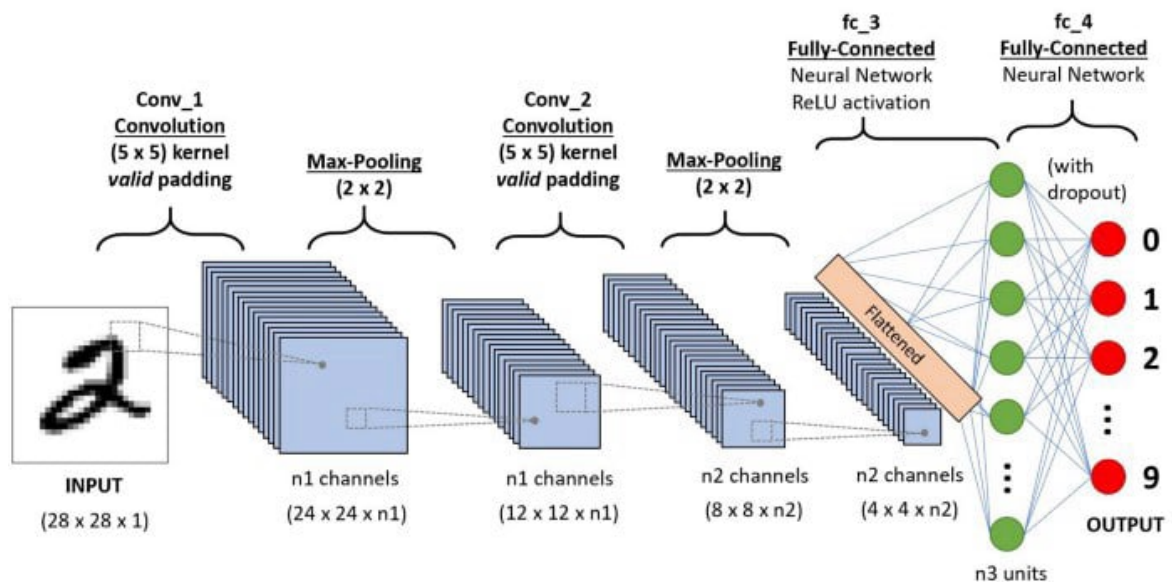


Figura 6: Ejemplo de la arquitectura de una CNN

Fuente: Baillot (2018)

2.1.4.2. Redes neuronales recurrentes

Una red neuronal recurrente (RNN, en sus siglas en inglés) es un tipo de red neuronal artificial que utiliza datos secuenciales o datos de series temporales. Estos algoritmos de DL se usan comúnmente para series temporales, como la traducción de idiomas, reconocimiento de voz y subtítulos de imágenes de video; se incorporan a aplicaciones populares como la búsqueda por voz y Google Traductor. Al igual que las CNN, las RNN utilizan datos de entrenamiento para aprender. Se distinguen por su “memoria”, ya que toman información de entradas anteriores para influir en la entrada y salida actual. Mientras que las redes neuronales profundas tradicionales asumen que las entradas y salidas son independientes entre sí, la salida de las redes neuronales recurrentes depende de los elementos previos dentro de la secuencia.

Las RNN son redes con bucles entre ellos (Figura 7). Estos bucles hacen que las redes neuronales recurrentes parezcan un poco misteriosas. Sin embargo, si piensas un poco más, resulta que no son tan diferentes de una red neuronal normal. Una RNN se puede considerar como varias copias de la misma red, cada una pasando un mensaje a un sucesor. Considere lo que sucede si se desenrolla el bucle.




Figura 7: Bucle de una RNN

Fuente: Olah (2015) <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Hay tres tipos de RNN (Figura 8), la simple propiamente dicha como RNN, la unidad de memoria a corto y largo plazo (LSTM, en sus siglas en inglés), y la Unidad Recurrente Cerrada (GRU, en sus siglas en inglés); esta investigación se enfoca en la LSTM, ya que es la red neuronal utilizada en la investigación.

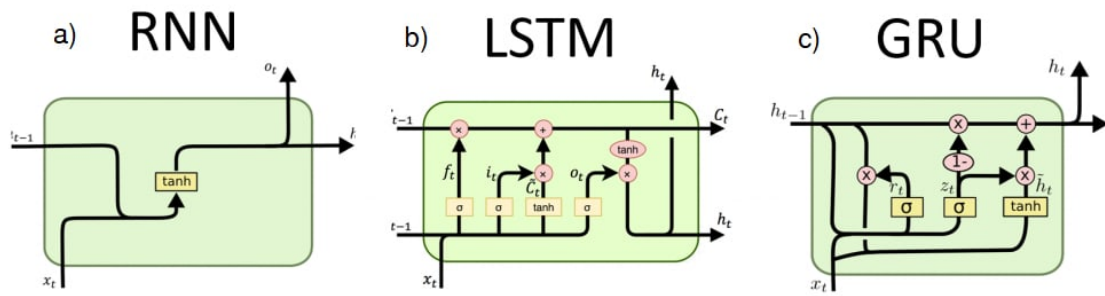


Figura 8: La red neuronal a) RNN, b) LSTM y c) GRU

Fuente: Olah (2015) <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

2.1.4.2.1. Red Neuronal de Memoria a Corto y Largo Plazo

Las redes de memoria a corto y largo plazo, normalmente llamadas LSTM, son un tipo especial de RNN, capaz de aprender dependencias a largo plazo. Fueron introducidos por Hochreiter y Schmidhuber (1997), y fueron refinados y popularizados por muchas personas en trabajos posteriores relacionadas a ENOS (Broni-Bedaiko *et al.* 2019). Funcionan tremendamente bien en una gran variedad de problemas, y ahora son ampliamente utilizados. Las redes neuronales LSTM están diseñadas explícitamente para evitar el problema de dependencia a largo plazo, quiere decir, a recordar información durante largos períodos de tiempo que es prácticamente su comportamiento predeterminado, no algo que les cuesta aprender.

Los LSTM también tienen esta estructura similar a una cadena, pero el módulo repetitivo tiene una estructura diferente. En lugar de tener una sola capa de red neuronal, hay cuatro que interactúan de una manera muy especial (Figura 9).




Figura 9: Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan

Fuente: Olah (2015) <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

2.1.4.3. Red neuronal ConvLSTM

La red Neuronal ConvLSTM es un tipo de red neuronal recurrente para la predicción espacio-temporal que tiene estructuras convolucionales tanto en las transiciones de entrada a estado como de estado a estado. La ConvLSTM determina el estado futuro de una determinada celda en la cuadrícula por las entradas y los estados pasados de sus vecinos próximos. Esto se puede lograr fácilmente mediante el uso de un operador de convolución en las transiciones de estado a estado y de entrada a estado (Figura 10).




Figura 10: Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan

Fuente: Shi *et al.* (2015)

Shi *et al.* (2015) proponen usar las imágenes secuenciales, con un enfoque de uso de capas ConvLSTM, para pronosticar y clasificar imágenes secuenciales en 2D o 3D. Primeramente, la red neuronal ConvLSTM, es una capa neuronal recurrente, del tipo LSTM, pero las

multiplicaciones de matriz interna se intercambian con operaciones de convolución (usa la red neuronal CNN). Como resultado, los datos que fluyen a través de las celdas ConvLSTM (Figura 11) mantienen la dimensión de entrada (2D o 3D en este caso) en lugar de ser solo un vector 1D con sus respectivas características.

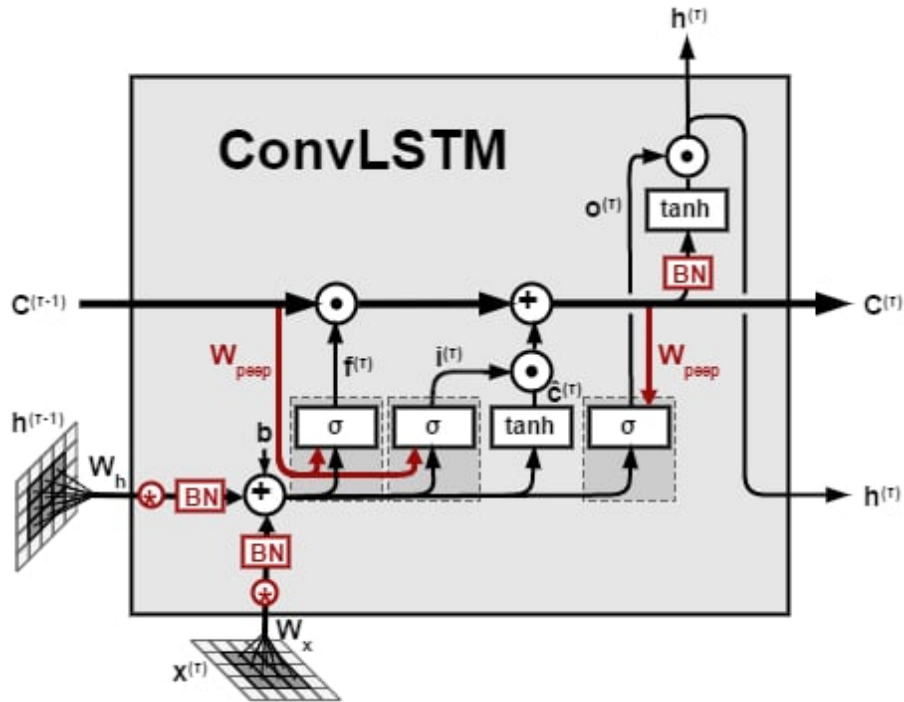


Figura 11: Bucle de una LSTM, el módulo repetitivo contiene cuatro capas que interactúan

Fuente: Akouaydi *et al.* (2019)

La ConvLSTM tiene la siguiente metodología de uso, de la información de imágenes (matrices en 2D Y 3D) usa los datos de los períodos sucesivos de tiempo que lo caracteriza como una serie temporal. Por lo tanto, utiliza el enfoque del modelo basado en redes neuronales LSTM. En este tipo de arquitectura, el modelo pasa el estado oculto anterior al siguiente paso de la secuencia. Por consiguiente, mantiene información sobre datos anteriores que la red ha visto antes y lo utiliza para tomar decisiones. En otras palabras, el orden de datos es extremadamente importante.

Además, como se está trabajando con matrices (imágenes en 2D o 3D), el mejor enfoque es una arquitectura CNN (Figura 6) por lo ya mencionado en la sección 2.1.4.1; por lo tanto, a nuestras imágenes (matrices 2D o 3D) se le pasa a través de capas convolucionales, en las que varios filtros extraen entidades importantes. Después de pasar algunas capas

convolucionales en secuencia, la salida está conectada a una red densa totalmente conectada.

En resumen, se afirma que la ConvLSTM es una unión entre la LSTM y la CNN.

2.2. EL NIÑO OSCILACIÓN DEL SUR Y EL FENÓMENO DEL NIÑO

2.2.1. 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 comenta, que la primera descripción de un evento El Niño fue realizada por Carranza (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 concepto del fenómeno El Niño ha ido variando a lo largo de los años. En países de Sudamérica como Perú y Ecuador, se denomina El Niño al incremento de la TSM en el litoral de la costa oeste de Sudamérica con ocurrencia de lluvias intensas.

2.2.2. El Niño Oscilación del Sur

Según la WMO (2014) ENOS es un fenómeno natural caracterizado por la fluctuación e interacción de la temperatura del océano en la parte central y oriental del Pacífico ecuatorial, asociada a cambios en la atmósfera, así mismo, 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 (Figura 12).

Para una mejor comprensión y pronóstico de ENOS, las temperaturas de la superficie del mar se monitorean en cuatro regiones a lo largo del ecuador (Figura 31): Niño 1 (5S - 10S, 80W – 90W), Niño 2 (0 – 5S, 80W – 90W), Niño 3 (5N-5S, 90W - 150W), Niño 4 (5N-5S, 150E-160W).

Estas regiones se crearon a principios de la década de 1980. Desde entonces, la continuación de la investigación ha dado lugar a modificaciones de estas regiones originales. Los Niño 1 y Niño 2 originales ahora se combinan y se llama Niño 1+2 (0-10S, 80W-90W). Una nueva región, llamada Niño 3.4 (5N-5S, 120W-170W) ahora se utiliza por una mejor correlación con el Índice de Oscilación del Sur y es la región preferida para monitorear la TSM.

2.2.3. Condición del ENOS en el pacífico tropical

Las condiciones de ENOS en el Pacífico Tropical se realiza de tres eventos o condiciones, se describe primeramente las condiciones normales, posteriormente la condición El Niño y finalizando con la condición La Niña.

Condición Normal, la celda de circulación atmosférica caracterizada por masas de aire ascendente, convección atmosférica profunda y fuertes lluvias sobre aguas superficiales cálidas del Pacífico occidental y descenso sobre aguas superficiales más frías del Pacífico oriental se conoce como la Circulación de Walker (Walker y Bliss 1932). En la Figura 12 el afloramiento ecuatorial transporta agua fría hacia arriba desde el interior del océano para crear una “lengua fría” en la TSM que se extiende desde la costa de América del Sur hasta la línea de fecha internacional (tonos verde y azul). Al oeste de la lengua fría se encuentra la “piscina cálida” del Pacífico occidental (tonos naranja y rojo), que son las aguas más cálidas en el océano abierto de la Tierra. La termoclina es una región de rápido cambio de temperatura vertical que separa el cálido océano superior del frío interior profundo; su inclinación en dirección este-oeste está relacionada con la fuerza de los vientos alisios.




Figura 12: 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)

Condición El Niño, cuando los vientos alisios se debilitan durante El Niño (Figura 13), la piscina cálida se desplaza hacia el este, la termoclina se aplana y el afloramiento se reduce en la lengua fría. Las aguas superficiales inusualmente cálidas retroalimentan a la atmósfera para debilitar aún más los vientos alisios. A medida que el Pacífico central y oriental se calientan, las masas de aire ascendentes que provocan una convección atmosférica profunda y fuertes lluvias en el Pacífico occidental migran hacia el este con el agua caliente. El flujo de aire hacia el centro convectivo desde el oeste hace que los vientos alisios se debiliten aún más, lo que conduce a un mayor calentamiento de la superficie. De esta manera, la atmósfera y el océano quedan bloqueados en un bucle de retroalimentación positiva de refuerzo en el que los vientos debilitados y las temperaturas de la superficie del mar más cálidas continúan amplificándose. La terminación de El Niño es provocada por retroalimentaciones negativas demoradas que involucran procesos dinámicos oceánicos que eventualmente devuelven el sistema a la normalidad o, a veces, hacen que se exceda en condiciones frías de La Niña.

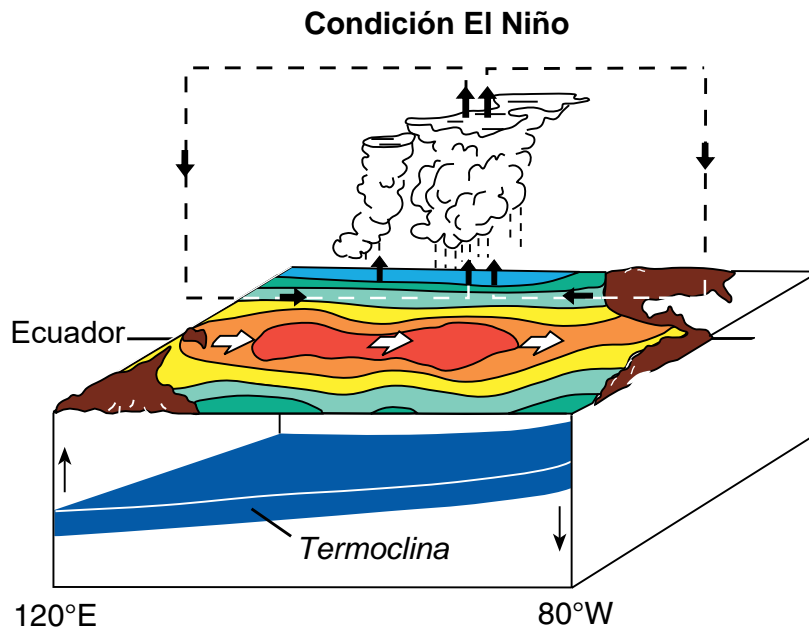


Figura 13: Modelo de temperaturas superficiales, vientos, áreas de aire ascendente y la termoclina (superficie azul) en el Pacífico tropical durante las condiciones El Niño
 Fuente: McPhaden (2018)

Condición La Niña, Durante La Niña, los vientos alisios intensificados crean una inclinación más pronunciada hacia el oeste hacia la termoclina (Figura 14), un afloramiento más intenso en la lengua fría y una piscina cálida desplazada más hacia el oeste, 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. 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 14: 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)

En los años de 1997 y 1998 se pudo observar las tres condiciones de ENOS, un evento particular ya que en enero del 1997 fue la transición de la condición normal a la condición El Niño (noviembre de 1997) y posteriormente se desarrolló la condición de La Niña (marzo del 1998), modificándose en cada etapa la TSM y la temperatura del mar profundo y por ende la inclinación de la termoclina en cada condición (Figura 15).




Figura 15: El perfil de la TSM y de la temperatura del agua profunda en el Océano Pacífico Ecuatorial, se ilustra cómo cambia la capa superior del océano durante la transición de la condición normal (enero 1997) a condición El Niño (noviembre de 1997) a la condición de desarrollo de La Niña (marzo del 1998)

Fuente: NOAA/PMEL (1998)

2.2.4. ENOS y las teleconexiones atmosféricas y su relación con la variabilidad climática

Según la Organización Meteorológica Mundial en su Guía sobre prácticas operativas para el pronóstico objetivo estacional del año 2020, denomina a las teleconexiones atmosféricas como patrones de anomalías recurrentes a gran escala que vinculan la variabilidad climática en regiones remotas de todo el mundo. El patrón del vaivén entre la presión de la superficie de Tahití y Darwin descubierto por Sir Gilbert Walker en el siglo XIX, llamado Oscilación del Sur (Walker y Bliss 1932), es quizás el primer ejemplo descubierto de teleconexión. Hoy se sabe que ENOS, un modo acoplado del océano y la atmósfera (Philander 1990) en el Pacífico tropical que evoluciona a través de la retroalimentación positiva entre la TSM y los vientos alisios, es el ejemplo más emblemático de teleconexión (WMO 2020).

ENOS influye en la distribución estacional de temperaturas y precipitaciones en varias regiones y depende de la estación (Trenberth *et al.* 1998; Davey *et al.* 2014). Cabe señalar que las influencias documentadas asociadas con ENOS representan respuestas típicas (no garantizadas). Por ejemplo, a menudo se observa que no hay eventos El Niño que sean idénticos en las respuestas meteorológicas y/o climáticas que generan en todo el mundo. Cuanto más fuerte sea El Niño, más probable es que se manifieste la influencia de la teleconexión. Los efectos más confiables de El Niño son precipitaciones deficientes sobre Indonesia y el norte de América del Sur y precipitaciones excesivas en el sureste de América del Sur, el este de África ecuatorial y el sur de los Estados Unidos (Ropelewski y Halpert 1987; Mason y Goddard 2001).

Por lo tanto, se menciona que las Figuras 16 y 17, durante un episodio de El Niño (La Niña), las áreas verdes o amarillas tienen la probabilidad de ser más húmedas (secas) que lo normal en los meses indicados.

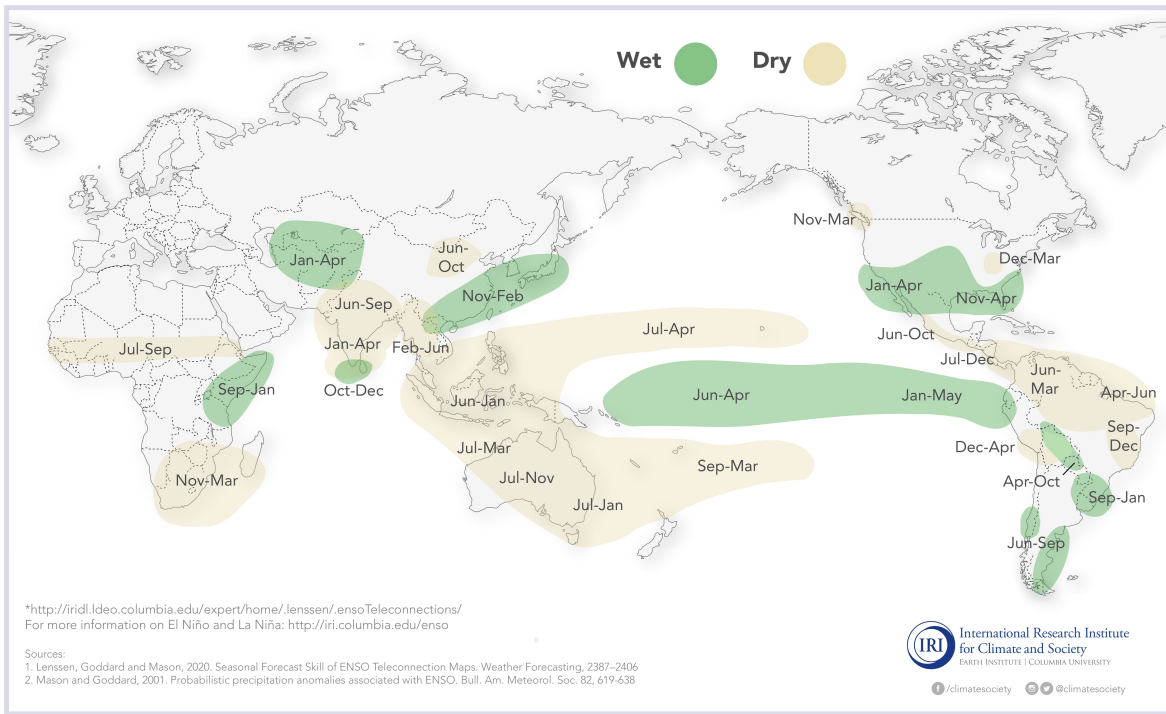


Figura 16: Los efectos de El Niño en el mundo descrito a través de teleconexiones

Fuente: <http://iridl.ldeo.columbia.edu/expert/home/.lenssen/.ensoTeleconnections/>

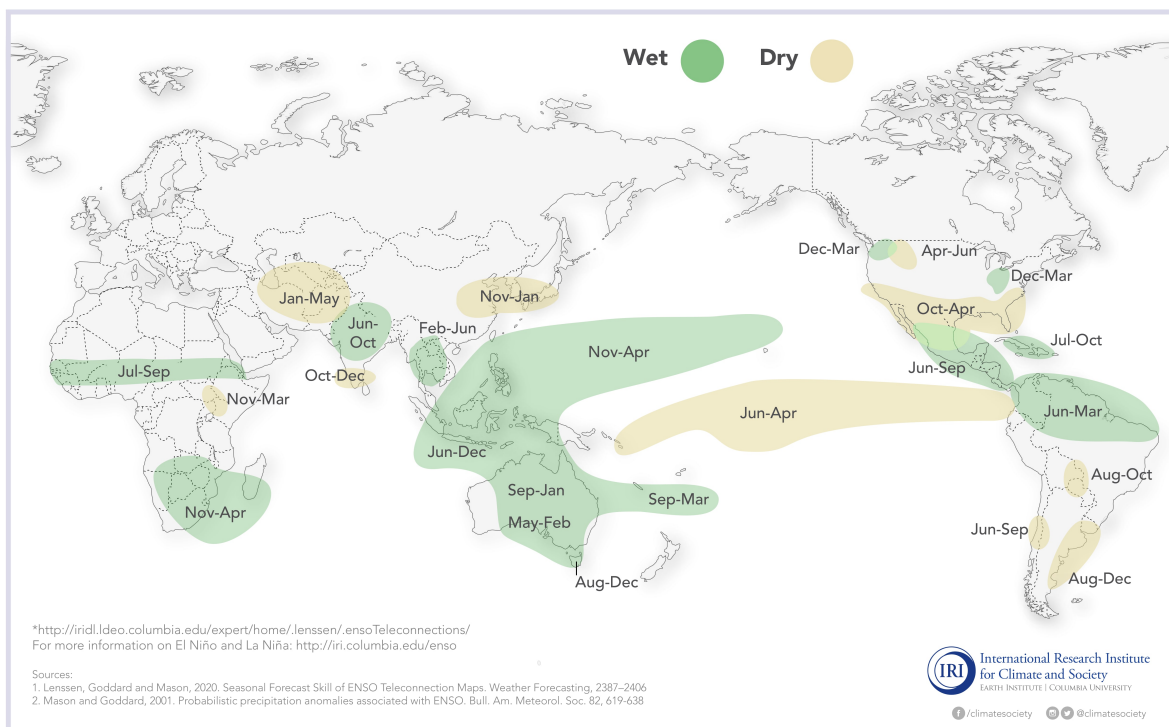


Figura 17: Los efectos de La Niña en el mundo descrito a través de teleconexiones

Fuente: <http://iridl.ldeo.columbia.edu/expert/home/.lenssen/.ensoTeleconnections/>

2.3. 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 (Figura 18). 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. En la Figura 18 muestra la ubicación de algunos índices climáticos más investigados que dan forma al tiempo y clima de la Tierra.

Los indicadores más empleados a nivel mundial para el ENOS son el ONI, MEI y el SOI, esto denotado por sus siglas en inglés y pueden ser descargados de la página <https://psl.noaa.gov/data/climateindices>.

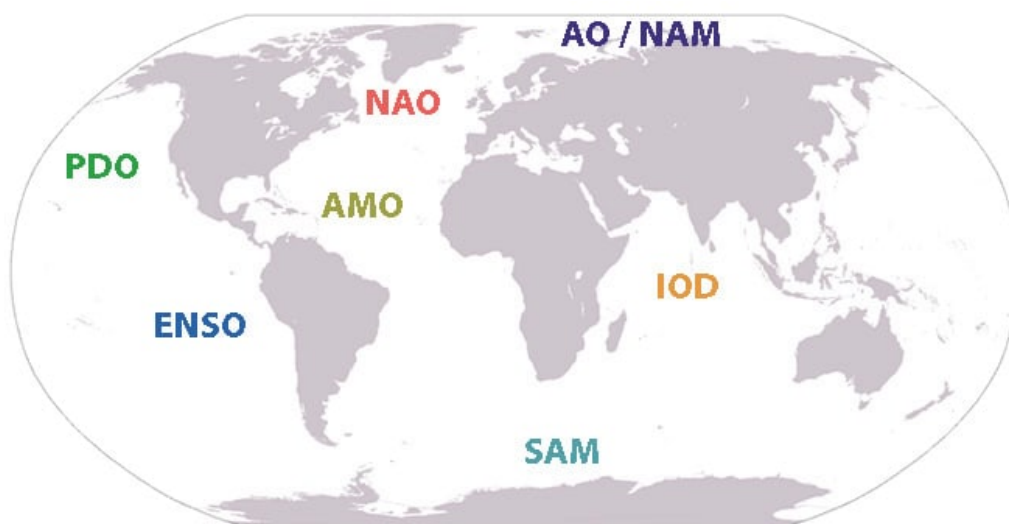


Figura 18: Ubicación geográfica de algunos de los índices más utilizados

Fuente: <https://news.ucar.edu/3779/weather-maker-patterns-world-map-view>

SOI (South Oscillation Index): El 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 (Figura 19). La ventaja añadida en el uso de la SOI es que los registros meteorológicos tienen más de 100 años de duración (Figura 20), lo que da más de un siglo de historia de ENOS.




Figura 19: Ubicación de las localidades en las que se mide la presión atmosférica. El signo de la diferencia entre los registros de Tahití y Darwin (Australia) indica la presencia de El Niño o La Niña

Fuente: http://klimat.czn.uj.edu.pl/enid/_2_Principales_sistemas_de_vientos/_-El_Ni_o_SOI_3ie.html




Figura 20: Índice SOI de la región Niño 3.4

Fuente: <https://psl.noaa.gov/people/cathy.smith/best>

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 21) 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 (Figura 22). Estos períodos base de 30 años se utilizan y actualizan para calcular las anomalías para períodos sucesivos de 5 años en el registro histórico.

Los eventos ONI se definen como cinco períodos consecutivos superpuestos de tres meses en o por encima de la anomalía de $+0.5^{\circ}\text{C}$ para eventos cálidos (El Niño), y en o por debajo de la anomalía de -0.5 para eventos fríos (La Niña). El umbral se divide en eventos Débiles (con una anomalía de la TSM de 0.5 a 0.9), Moderados (1.0 a 1.4) y Fuertes (≥ 1.5). Para que un evento sea categorizado como débil, moderado o fuerte, debe haber igualado o excedido el umbral durante al menos tres períodos consecutivos de tres meses superpuestos.




Figura 21: Índice ONI

Fuente: <http://www.webberweather.com/ensemble-oceanic-nino-index.html>

Elaboración propia

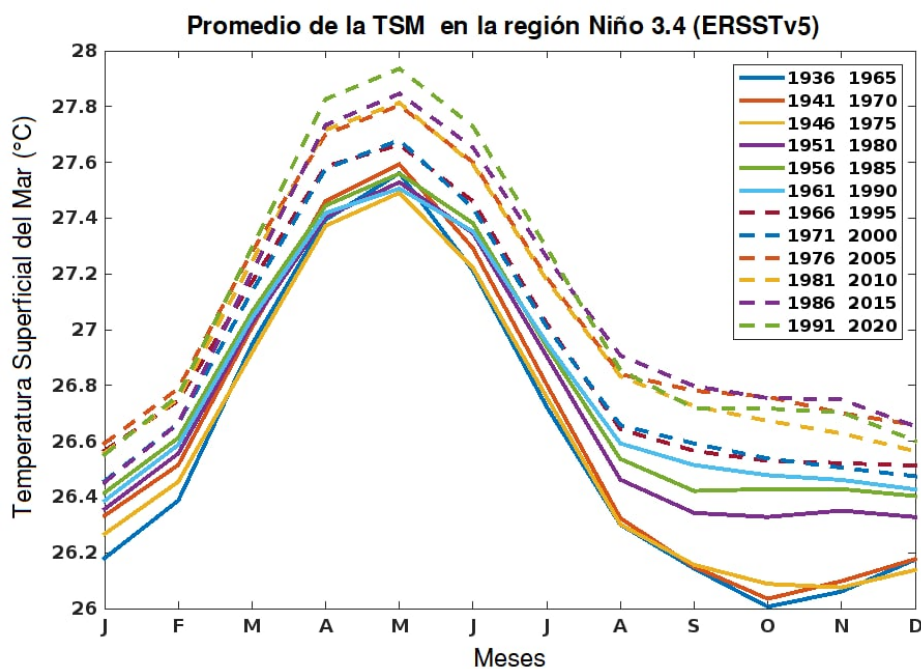


Figura 22: Promedio de la TSM en la región Niño 3.4, con periodo base cada 30 años, es utilizada como base de datos para la generación del Índice ONI

Fuente: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_change.shtml

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 23), 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>.

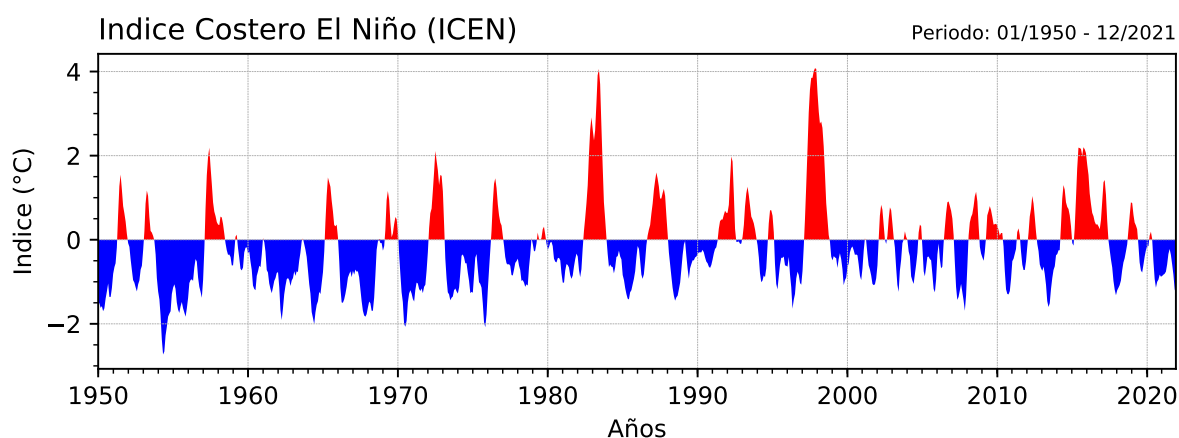


Figura 23: Índice ICEN

Fuente: <http://www.webberweather.com/ensemble-oceanic-nino-index.html>

Elaboración propia

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)

Índices E y C

Los índices E y C resumen la variabilidad asociada a El Niño y La Niña, representando el calentamiento superficial anómalo en el Pacífico este y centro, respectivamente. Debido a la forma en que fueron calculados (usando componentes principales) la correlación lineal entre ellos es baja, por lo que permite distinguir mejor la variabilidad propia de cada una de estas regiones (Takahashi *et al.* 2011).

En la Figura 24 se muestran los patrones de anomalías de temperatura superficial del mar asociados a valores unitarios de los índices E y C (Takahashi *et al.* 2011), respectivamente. El patrón E tiene mayor efecto en la costa peruana, pero el patrón C también puede ser relevante al clima en la zona andina o amazónica del Perú a través de las teleconexiones atmosféricas. (Bjerknes 1969; Glantz *et al.* 1991; Takahashi *et al.* 2011). Los datos están disponibles en: <http://met.igp.gob.pe/datos/EC.txt>.

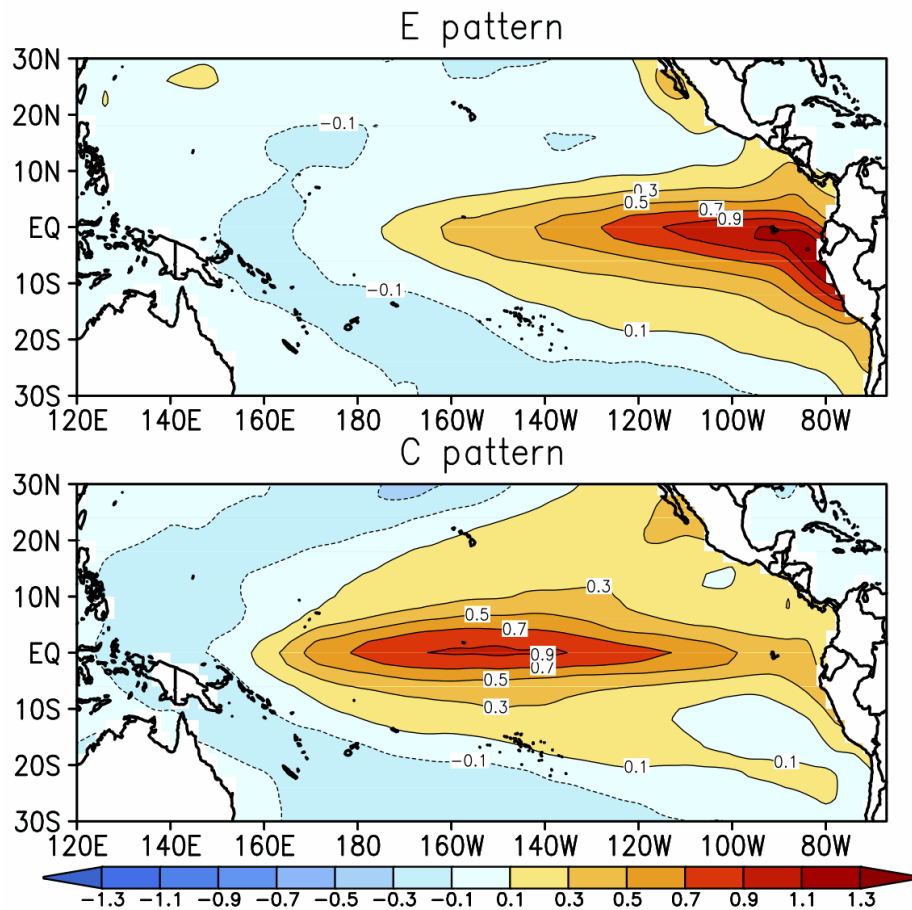


Figura 24: Índices E y C a nivel espacial en el pacífico tropical

Fuente: Takahashi *et al.* (2011)

Elaboración propia

2.4. 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 2018; Tang *et al.* 2018; 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.

¿Qué pronostican los modelos de ENOS?, todos los modelos pronostican la TSM o las ATSM en el Pacífico ecuatorial y/o en regiones Niño.

En la Figura 25 se muestra un resumen mensual (estacional) del pronóstico de la condición de El Niño, La Niña y normal o lo que se denomina ENOS, estos pronósticos son de modelos dinámicos y modelos estadísticos de centros de pronósticos de gran parte del mundo, basados en el índice Niño 3.4 (120-170W, 5S-5N) recopilado por Columbia Climate School International Research Institute for Climate and Society (IRI).

Los pronósticos mostrados en la Figura 25 son anomalías de la TSM para los períodos de 3 meses (estacionales) que se muestran para la región Niño 3.4 (120-170W, 5N-5S) del consolidado de modelos de IRI.

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.




Figura 25: Modelos de predicción IRI para ENOS en la región Niño 3.4 con respecto a las ATSM para el pronóstico de abril del 2014 a enero del 2016 de modelos dinámicos y estadísticos

Fuente: <https://iri.columbia.edu/our-expertise/climate/enso/>

Si bien los modelos de pronóstico continúan mejorando, la previsibilidad de ENOS está limitada por una serie de factores. Los pronósticos son más difíciles de enero a abril (lo que se conoce como la “barrera de previsibilidad de la primavera en el hemisferio norte”), lo que significa que El Niño está en marcha antes de que los modelos pronostiquen su aparición (Cane y Zebiak 1989; McPhaden 1999). Los procesos estocásticos, el forzamiento externo por eventos climáticos, ayudan a mantener la variabilidad de ENOS.

ENOS también está modulado por fluctuaciones decenales como la Oscilación Decenal del Pacífico (Zhang *et al.* 1997). Los procesos dinámicos que contribuyen a la “barrera de previsibilidad de primavera en el hemisferio norte” no se entienden, pero la habilidad de pronóstico del modelo mejora en algunas décadas y disminuye en otras.

Toda esta mejora de la habilidad de pronóstico de ENOS estacional y mensual se hace con el fin de que los tomadores de decisiones se beneficien de esta información y opten por las decisiones más correctas y preventivas de una determinada región o país, porque bien es sabido en lo mencionado en la sección 2.2.4, los impactos de ENOS varían geográficamente y estacionalmente en el todo el mundo de forma distinta (Figuras 16 y 17).

Específicamente, en el caso de Perú, Gonzales y Ingol (2021); determinaron la generación y ocurrencia del Niño costero mediante un índice denominado PREI, a través del cual se pueden controlar los probables aumentos de temperatura de la zona Niño 1+2 que pueden producirse durante los meses de enero a marzo de un año determinado y permitiendo una correcta gestión de los desastres relacionados con la ocurrencia de un ENOS costero.

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

Fuente: <https://iri.columbia.edu/our-expertise/climate/enso/>

2.5. MONITOREO DE ENOS EN EL OCÉANO PACÍFICO

El monitoreo del ENOS requiere observaciones tanto de la atmósfera como de los océanos. Estas observaciones a menudo se resumen en términos de varios índices atmosféricos y oceánicos. Algunos índices se basan en la desviación absoluta, o anomalía, del promedio a largo plazo de una variable en una región o regiones (Niño 1+2, Niño 3, Niño 4 y Niño 3.4).

El monitoreo de ENOS por la comunidad científica se hacen mediante las siguientes técnicas: radiómetros en tiempo real, altimetría satelital (altímetros de radar), información satelital para la medición indirecta de cómo cambia la altura de agua debido a la expansión de del agua caliente, información satelital para el monitoreo de vientos y precipitaciones, boyas y flotadores en el océano pacífico. Esta sección se enfoca al monitoreo mediante boyas y flotadores en el océano pacífico.

2.5.1. Matriz oceánica de la atmósfera tropical (TAO)

El Servicio Meteorológico Nacional en el Centro Nacional de Boyas de Datos (NDBC, en sus siglas en inglés) es un esfuerzo multinacional para proporcionar datos en tiempo real para la investigación y el pronóstico del clima. Uno de sus componentes principales de toma de datos es la matriz Oceánica de la Atmósfera Tropical TAO/TRITON en el océano Pacífico (Figura 26).

El conjunto TAO/TRITON fue diseñado para comprender y predecir mejor las variaciones climáticas relacionadas con ENOS. TAO/TRITON se construyó durante el período de 10 años de 1985-1994 y actualmente cuenta con el apoyo de los Estados Unidos, específicamente de la NOAA/Servicio Meteorológico Nacional y el Centro Nacional de Datos de Boyas y de Japón con la Agencia Japonesa de Ciencias y Tecnologías Marinas y Terrestres.

En la actualidad el NDBC tiene 2 funciones primordiales, primero, mantener la continuidad de las observaciones existentes para el registro climático y, segundo asegurar sus futuras contribuciones y supervivencia mediante una actualización integral del equipo, conocida como TAO, utilizando el sistema autónomo de adquisición de línea de temperatura (ATLAS) de próxima generación (Figura 27), para la obtención de registro climáticos.




Figura 26: Mapa de ubicación de las Boyas de TAO/TRITON en el Océano Pacífico

Fuente: <https://www.pmel.noaa.gov/gtmba/taotriton-map>

El diseño de la boya económica ATLAS fue iniciado por la División de Desarrollo de Ingeniería (EDD, en sus siglas en inglés) en 1984. A mediados de la década de 1990, se estaba realizando un esfuerzo de reingeniería para modernizar la boya ATLAS con énfasis en: mejorar la calidad de los datos, agregando nuevos sensores, aumento de la resolución temporal de los datos registrados internamente, mejorar la confiabilidad para extender la vida útil del sistema, simplificación de los procedimientos de fabricación y la reduciendo costos.

2.5.2. El programa ARGO

Históricamente, nuestra comprensión del océano proviene de información satelital, observaciones desde barcos, boyas amarradas y otros instrumentos anclados. Los flotadores ARGO son robóticos y pueden muestrear mucho más del océano global (Figura 28), proporcionando casi cuatro veces más información que todas las demás herramientas de observación del océano combinadas.

ARGO es un programa internacional que hace el despliegue de más de 3000 flotadores perfiladores distribuidos en los océanos del mundo, que medirán la temperatura y la salinidad (T/S) en los 2000 metros superiores del océano (Figura 29) proporcionando 100000 perfiles T/S y mediciones de velocidad de referencia al año. Este conjunto global a gran escala de flotadores perfiladores de T/S ya se ha convertido en un componente importante del sistema de observación del océano. El programa ha cambiado la forma en que los científicos piensan sobre la recopilación de datos y ha proporcionado beneficios adicionales, como, por ejemplo,

cómo colaborar internacionalmente y cómo desarrollar una gestión de datos que pueda ser utilizada por la comunidad científica. Los datos son cruciales para el pronóstico del tiempo del clima y el océano biológico.




Figura 27: Esquema del modelo de boya ATLAS de próxima generación

Fuente: https://tao.ndbc.noaa.gov/proj_overview/mooring_ndbc.shtml

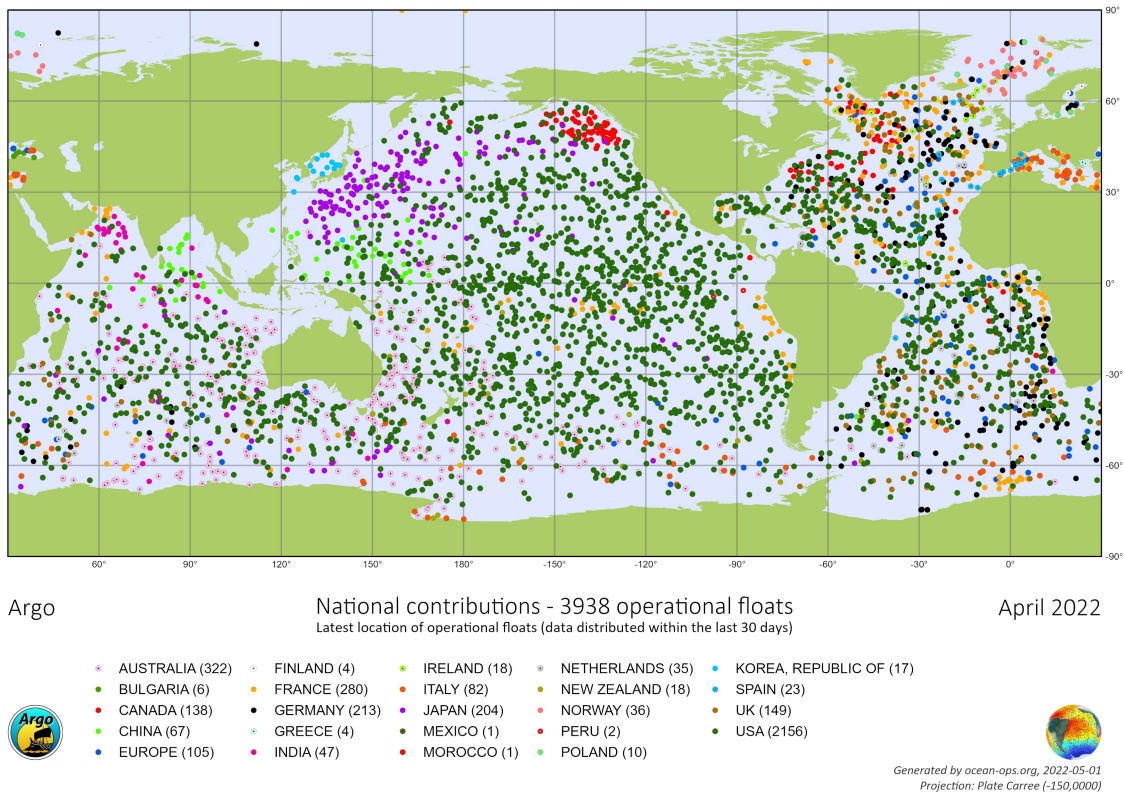


Figura 28: Mapa mundial de ubicación de los flotadores ARGO en el océano global

Fuente: <https://www.ocean-ops.org/board?t=argo/>




Figura 29: Esquemización de perfil del flotador ARGO a distintas profundidades en el océano

Fuente: Institución Oceanográfica de Woods Hole

2.6. MÉTRICAS ESTADÍSTICAS PARA EL PRONÓSTICOS ENOS

La idea de construir modelos de ML y DL funciona con un principio de retroalimentación constructiva. El cual se resume en lo siguiente: Primeramente, se construye un modelo, se realiza cálculos de las métricas estadísticas del modelo y se obtiene comentarios de esas métricas estadísticas, se realiza mejoras continuas hasta que se logre una precisión deseable.

Las métricas estadísticas explican el rendimiento de un modelo, un aspecto importante de las métricas estadísticas es su capacidad para discriminar entre los resultados del modelo.

Las métricas estadísticas en ML se utilizan para evaluar la bondad de los pronósticos. El error cuadrático medio (MSE, en sus siglas en inglés), la raíz del error cuadrático medio (RMSE, en sus siglas en inglés), el error absoluto medio (MAE, en sus siglas en inglés), la raíz del error cuadrático medio Porcentual (RSMPE, en sus siglas en inglés) y el error porcentual absoluto medio (MAPE, en sus siglas en inglés) son las métricas de precisión más utilizadas para la evaluación de las RNA. Sin embargo, diferentes métricas estadísticas de precisión se basan en diferentes tipos de medidas. Por ejemplo, los cálculos de MSE, RMSE y MAE se basan en errores cuadráticos y errores absolutos. Los cálculos de MAPE y RMSPE se basan en errores porcentuales. Diferentes métricas de precisión muestran diferentes tipos de bondad. Dado que las diferentes métricas de precisión tienen sus propias ventajas y desventajas, para un modelo de pronóstico específico, algunas métricas de precisión pueden no ser adecuadas. Por lo tanto, la selección de una métrica de precisión adecuada para evaluar los modelos de pronóstico de ML es un tema muy importante.

2.6.1. Métricas estadísticas de precisión

2.6.1.1. Métricas estadísticas basadas en correlación

El coeficiente de correlación (R) y el coeficiente de determinación (R^2) son ampliamente utilizados para la evaluación de la bondad del ajuste lineal de los modelos de regresión en RNA, ML y DL (Kvålseth 1985). El coeficiente de correlación de Pearson (conocido como r), el coeficiente de correlación de Spearman y el coeficiente de correlación de Kendall son coeficientes de correlación de uso común en estadística. El valor de r interpreta el grado de correlación entre las variables reales y predichas.

El cálculo de r es de la siguiente manera, el numerador es la suma de los cuadrados de los residuos, también llamada suma residual de los cuadrados, y el denominador es la suma total de los cuadrados que es proporcional a la varianza de los datos. Se muestra la ecuación 1 de Pearson.

$$r_{x,y} = \frac{cov(x, y)}{S_x \cdot S_y} = \frac{\frac{1}{N-1} \sum_{i=1}^N [(x_i - \bar{x}) \cdot (y_i - \bar{y})]}{\sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \cdot \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

Donde:

$r_{(x,y)}$: Coeficiente de correlación de Pearson entre las variables x e y .

$Cov_{(x,y)}$: Covarianza de las variables x e y .

S_x, S_y : Desviación Estándar de x e y .

x_i, y_i : Valores de x e y .

\bar{x}, \bar{y} : Valores promedio de x e y .

La magnitud de r varía de -1 a $+1$ (Ali *et al.* 2020). La magnitud de la correlación de dos variables se puede describir en cinco rangos (Figura 30). Un valor de $+1$ (o -1) indica la correlación perfecta entre dos variables, $+1$ es una correlación positiva y -1 es una correlación inversa (negativa) entre dos variables, más detalles en la Tabla 3.

Tabla 3: Evaluación del pronóstico de la magnitud de r

Valor de r	Precisión del Pronóstico
$r = +1(-1)$	Correlación perfecta
$+0,8 < r < +1(-0,8 > r > -1)$	Correlación muy fuerte
$+0,6 < r < +0,8(-0,6 > r > -0,8)$	Correlación fuerte
$+0,4 < r < +0,6(-0,4 > r > -0,6)$	Correlación moderada
$+0,2 < r < +0,4(-0,2 > r > -0,4)$	Correlación débil
$0 < r < +0,2(0 > r > -0,2)$	Correlación muy débil
$r = 0$	Correlación nula

Fuente: Elaboración propia

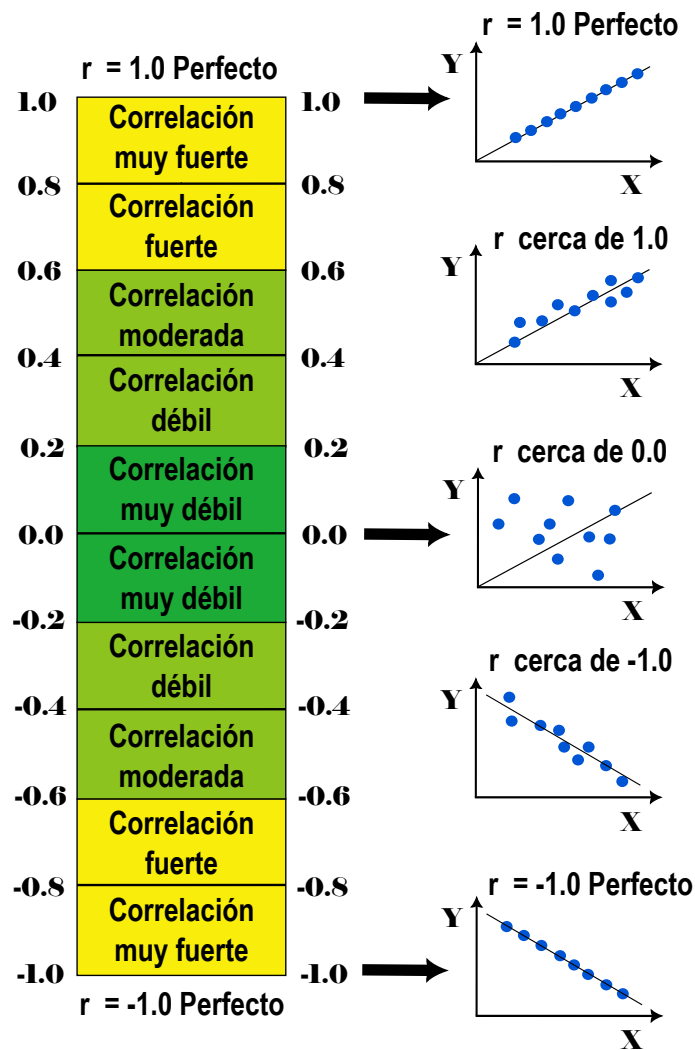


Figura 30: Rango de correlación de r

Fuente: Elaboración propia

2.6.1.2. Métricas estadísticas dependientes de la escala

Las métricas basadas en errores absolutos o en errores cuadráticos se denominan métricas dependientes de la escala (Hyndman 2006; Hyndman y Koehler 2006). Las métricas dependientes de la escala tienen la misma escala que los datos originales (Hyndman 2006) y proporcionan errores en las mismas unidades (Sanders 1997). Sin embargo, las métricas dependientes de la escala pueden ser difíciles de comparar para series que están en escalas diferentes o que tienen unidades diferentes. Por ejemplo, si un error de predicción es de 10 unidades, la gravedad del error no puede evaluarse a menos que también se proporcione el nivel de gravedad (Flores 1986). Aunque las métricas dependientes de la escala no están libres de unidades, se favorecen en la evaluación del ML. Las métricas estadísticas

dependientes de la escala comúnmente utilizadas son MSE, RMSE y MAE.

Las ecuaciones de las tres métricas estadísticas (Kim C.H y Kim Y.C 2020) se definen como:

Error Cuadrático Medio (*MSE*, en sus siglas en inglés)

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 \quad (2)$$

Raíz del Error Cuadrático Medio (*RMSE*, en sus siglas en inglés)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2} \quad (3)$$

Error Absoluto Medio (*MAE*, en sus siglas en inglés)

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}| \quad (4)$$

Donde, para todas las ecuaciones anteriores, se tiene:

y_i : Valores observados

\bar{y} : Valores pronosticados

N : Número total de datos

MSE mide el error cuadrático medio entre el valor pronosticado y el valor real. Para cada punto de datos, la distancia se mide verticalmente desde el valor real hasta el valor pronosticado correspondiente en la línea de ajuste, y el valor se eleva al cuadrado. Posteriormente, se calcula la suma de todos los valores al cuadrado y se divide por el número de puntos. Por lo tanto, la unidad de MSE es el cuadrado de la unidad original. Debido al cuadrado de los errores, los valores negativos y los valores positivos no se anulan entre sí. El rango de MSE es $(0, +\infty)$; cuanto menor sea el valor de MSE, mayor será la precisión del modelo de predicción. El valor perfecto de MSE es 0, lo que indica que el modelo de predicción es perfecto. MSE está predeterminado como la función de pérdida de regresión lineal en el ML.

RMSE mide la magnitud promedio del error entre el valor pronosticado y el valor real. Por lo tanto, RMSE es la distancia promedio medida verticalmente desde el valor real hasta el valor pronosticado correspondiente en la línea de ajuste. Simplemente, es la raíz cuadrada de MSE. De la misma manera que MSE, el rango de RMSE es $(0, +\infty)$; cuanto menor sea el valor de RMSE, mayor será la precisión del modelo de predicción. En contraste con MSE, las unidades de RMSE son las mismas que las unidades originales, lo que hace que RMSE sea más interpretable que MSE.

MAE es una métrica utilizada para medir la magnitud promedio de los errores absolutos entre el valor pronosticado y el valor real. El MAE a menudo se denomina desviación absoluta media (*MAD*, en sus siglas en inglés) (Flores 1986; Sanders 1997). El rango de MAE es $(0, +\infty)$; cuanto menor sea el valor de MAE, mayor será la precisión del modelo de predicción. La ventaja de MAE es que la unidad de MAE es la misma que la de los datos originales y es fácil de calcular y comprender. El MAE se utiliza a menudo como una función de pérdida simétrica (Flores 1986).

Tanto MAE como RMSE expresan la magnitud promedio del error de predicción con las unidades de los datos originales. En comparación con MAE, el RMSE tiene un peso relativamente alto para errores grandes, porque los errores se elevan al cuadrado antes de promediarlos. Si los errores de predicción se distribuyen normalmente, el MAE y el RMSE se pueden intercambiar entre sí con la ecuación 5, que se define como (Flores 1986; Sanders 1997):

$$RMSE = 0,8 \cdot MSE \quad (5)$$

En resumen, las métricas estadísticas dependientes de la escala MSE, RMSE y MAE penalizan los errores según su magnitud (Sanders 1997). La desventaja de estas tres métricas es que no están libres de unidades y es difícil comparar predicciones con diferentes unidades. Además, MSE, RMSE y MAE interpretan solo la magnitud del error, pero no indican la dirección del error.

2.6.1.3. Métricas estadísticas dependientes del porcentaje

Para comparar predicciones con diferentes unidades, se necesitan medidas sin unidades. Dado que no hay limitación de unidades, se prefieren las métricas dependientes de porcentajes (Hyndman y Koehler 2006) para este problema. Las métricas dependientes del porcentaje miden el tamaño de los errores en términos porcentuales y proporcionan un pensamiento interpretable con respecto a la calidad de la predicción (Sanders 1997; Makridakis *et al.* 2008). El pensamiento interpretable debe expresarse en términos porcentuales cuando se desconoce la escala de los datos. Por ejemplo, un informe que diga que “el error de pronóstico es del 2 por ciento” es más significativo que decir “El error de pronóstico de 2 °C”, si el revisor investigador no conoce la escala de los datos.

Las métricas estadísticas dependientes de porcentaje más utilizadas son MAPE y RMSPE (Jamieson *et al.* 1991; Armstrong y Collopy 1992; Hyndman y Koehler 2006; Makridakis *et al.* 2008), y se definen como (Chen *et al.* 2003; Li *et al.* 2013):

Raíz del Error Cuadrático Medio Porcentual (*RMSPE*, en sus siglas en inglés)

$$RMSPE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \bar{y}_i}{y_i} \right)^2} \cdot 100 \quad (6)$$

Error Porcentual Absoluto Medio (*MAPE*, en sus siglas en inglés)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \bar{y}_i}{y_i} \right| \cdot 100 \quad (7)$$

Donde, para todas las fórmulas anteriores, se tiene:

y_i : Valores observados

\bar{y} : Valores pronosticados

N : Número total de datos

Según Jamieson *et al.* (1991) y Li *et al.* (2013) el RMSPE (Tabla 4) es una medida de la precisión del pronóstico, con el RMSPE, se tiene una idea más clara de la magnitud de RMSE en relación con los valores reales, ya que esta expresado en forma porcentual.

Tabla 4: Evaluación del pronóstico del valor de *RMSPE*

Valor de <i>RMSPE</i> (En Porcentajes)	Precisión del Pronóstico
$RMSPE < 10$	Excelente
$10 < RMSPE \leq 20$	Bueno
$20 < RMSPE \leq 30$	Regular
$RMSPE > 30$	Malo

Según Lewis (1982) y Chen *et al.* (2003), El MAPE calcula el promedio del porcentaje de error absoluto, especialmente en la estimación de tendencias. El MAPE se utiliza como función de pérdida para modelos de regresión en ML, ya que es muy intuitivo para explicar el error relativo. La desventaja del MAPE es que, MAPE es sensible a la escala; obtendrá valores extremos si el valor real es bastante pequeño. Por lo tanto, el MAPE debe evitarse como una métrica de evaluación para datos de baja escala. Otra desventaja del MAPE es que penaliza más los errores positivos que los errores negativos (Armstrong y Collopy 1992; Sanders 1997; Hyndman 2006). En la Tabla 5 se muestran los rangos de valores de MAPE y su precisión de pronóstico (Lewis 1982; Chen *et al.* 2003).

Tabla 5: Evaluación del pronóstico del valor de *MAPE*

Valor de <i>MAPE</i> (En Porcentajes)	Precisión del Pronóstico
$MAPE < 10$	Excelente
$10 < MAPE \leq 20$	Bueno
$20 < MAPE \leq 50$	Regular
$MAPE > 50$	Malo

2.7. LA TRANSFORMADA ONDELETA

El objetivo básico de análisis ondeleta (*Wavelet*, en sus siglas en inglés) es tanto para determinar el contenido de frecuencia (o escala) de una señal y para evaluar y determinar la variación temporal de este contenido de frecuencia (Heil y Walnut 1989). Por lo tanto, la transformada de ondeleta es la herramienta de elección cuando las señales son caracterizadas por eventos de alta frecuencia localizados o cuando señales se caracterizan por un gran número de escala y de los procesos variables. Debido a sus propiedades de localización tanto en el tiempo y la escala, la transformada ondeleta permite el seguimiento de la evolución en el tiempo de los procesos a diferentes escalas en la señal.

2.7.1. La transformada ondeleta continua (CWT)

La transformada en ondeleta es una herramienta matemática que permite descomponer una serie de tiempo en el dominio tiempo-frecuencia, y por tanto es posible determinar los modos dominantes de variabilidad y como varían tales modos con el tiempo (Torrence y Compo 1998). Esta transformada se define como:

$$W_{(x,t)} = \int_{-\infty}^{\infty} f(u)\psi_{\lambda,t}(u)du \text{ para } \lambda > 0 \quad (8)$$

Donde λ es el parámetro de escala (dilatación), t es el parámetro de localización (traslación) y ψ_t es la ondeleta madre. Una constante de normalización ($\frac{1}{\sqrt{\lambda}}$) es escogida de tal manera $\int |\psi_{\lambda,t}|^2 du = \int |\psi_t|^2 dt$ que para todas las escalas. La transformada discreta en ondeletas se define como la convolución de X_n con una versión trasladada y escalada de la ondeleta madre $\psi_0(n)$, donde n es un parámetro adimensional del tiempo.

$$W_n(s) = \sum_{n'=0}^{N-1} x_{n'}\psi^* \left(\frac{(n' - n)\Delta t}{s} \right) \quad (9)$$

ψ hace referencia al conjugado complejo, s es el parámetro de escala y n el parámetro de localización. Así, la energía se define como el cuadrado de la magnitud de la transformada en ondeletas:

$$E_{\lambda,t} = |W_{\lambda,t}|^2 \quad (10)$$

La transformada en ondeletas localiza temporal y frecuencialmente la señal, pues su espectro de potencias es un mapa de curvas de nivel (dos dimensiones) representadas en un marco definido por un eje temporal y uno frecuencial (Daubechies 1990; Torrence y Compo 1998).

2.7.2. Transformada ondeleta coherencia (WTC)

La potencia de ondeleta Cruzada revela áreas con alto poder en común. Otra medida útil es la forma coherente de la transformada ondeleta cruzada está en el espacio de tiempo y frecuencia. Torrence y Webster (1999) definieron la ondeleta coherencia de dos series de tiempo como:

$$R_n^2(s) = \frac{|S(s^{-1}W_n^{XY}(s))|^2}{S(s^{-1}|W_n^X(s)|^2) \bullet S(s^{-1}|W_n^Y(s)|^2)} \quad (11)$$

Donde S es un operador de suavizado. Observe que esta definición se asemeja mucho a la de un coeficiente de correlación tradicional, y es útil pensar en la ondeleta coherencia como un coeficiente de correlación localizada en el espacio de tiempo y frecuencia. Se escribe el operador suavizado S como:

$$S(W) = S_{scale}(S_{time}(W_n(s))) \quad (12)$$

Donde S_{scale} denota suavizado a lo largo del eje de escala ondeleta y S_{time} suavizado en el tiempo. Es natural para diseñar el operador de suavizado, de manera que tiene una huella similar a la ondeleta utilizado. Para la ondeleta de Morlet un operador de suavizado adecuada viene dada por Torrence y Webster (1999).

$$\begin{aligned} |S_{time}(W)|_s &= \left| \left(W_n(s) * c_1 \frac{-t^2}{2s^2} \right) \right|_s \\ |S_{time}(W)|_s &= |(W_n(s) * c_2 \Pi(0,6s))|_s \end{aligned} \quad (13)$$

Donde c_1 y c_2 son constantes de normalización y π es la función rectángula. El factor de 0.6 es la longitud de descorrelación de escala determinado empíricamente para la ondeleta de Morlet (Torrence y Compo 1998). En la práctica ambas circunvoluciones se realizan por separado y, por tanto, los coeficientes de normalización se determinan numéricamente. El nivel de significación estadística de la ondeleta coherencia se estima usando el método de Monte Carlo. Se genera un gran conjunto de pares de conjuntos de datos de sustitución con los mismos coeficientes $AR1$ como los conjuntos de datos de entrada. Para cada par se calcula la coherencia ondeleta. Luego se estima el nivel de significación para cada escala utilizando únicamente los valores fuera de la COI. Prueba empírica muestra que los coeficientes $AR1$ tienen poco impacto en el nivel de significación. Los detalles de la operadora de suavizado, sin embargo, tienen un gran impacto (Torrence y Compo 1998).

III. MATERIALES Y MÉTODOS

3.1. DESCRIPCIÓN DEL ÁREA DE ESTUDIO

Para pronosticar e identificar los eventos ENOS, se seleccionó el área que comprende los 10°S-10°N, 140°E-80°W (Figura 31). Para una mejor muestra de datos de medición y precisión de la TSM, el pacífico ecuatorial se ha dividido en varias regiones denominadas Niño 1+2, Niño 3, Niño 4 y Niño 3.4.

La presente investigación tiene como localización y área de estudio a las regiones Niño (Figura 31), se detalla la ubicación de estas regiones.

Niño 1+2 (0-10S, 90W-80W): Esta región es la más oriental del pacífico ecuatorial y la más pequeña, y corresponde a la región costera de América del Sur donde. Fue en esta región que El Niño fue registrado por primera vez por pobladores locales (Perú), es la región más monitoreada por el Perú.

Niño 3 (5N-5S, 150W-90W): Esta región fue anteriormente el área y ubicación principal para monitorear y pronosticar ENOS, pero años más tarde los investigadores descubrieron que la región principal y clave para monitorear las interacciones del océano y la atmósfera para ENOS se encuentra más al oeste (Trenberth 1997).

Niño 4 (5N-5S, 160E-150W): Región más occidental de las regiones Niño del pacífico ecuatorial central.

Niño 3.4 (5N-5S, 170W-120W): Esta región para el mundo entero, es considerada el foco principal para monitorear y predecir ENOS, y partir de esta región se calcula varios índices climáticos de ENOS para su monitoreo.

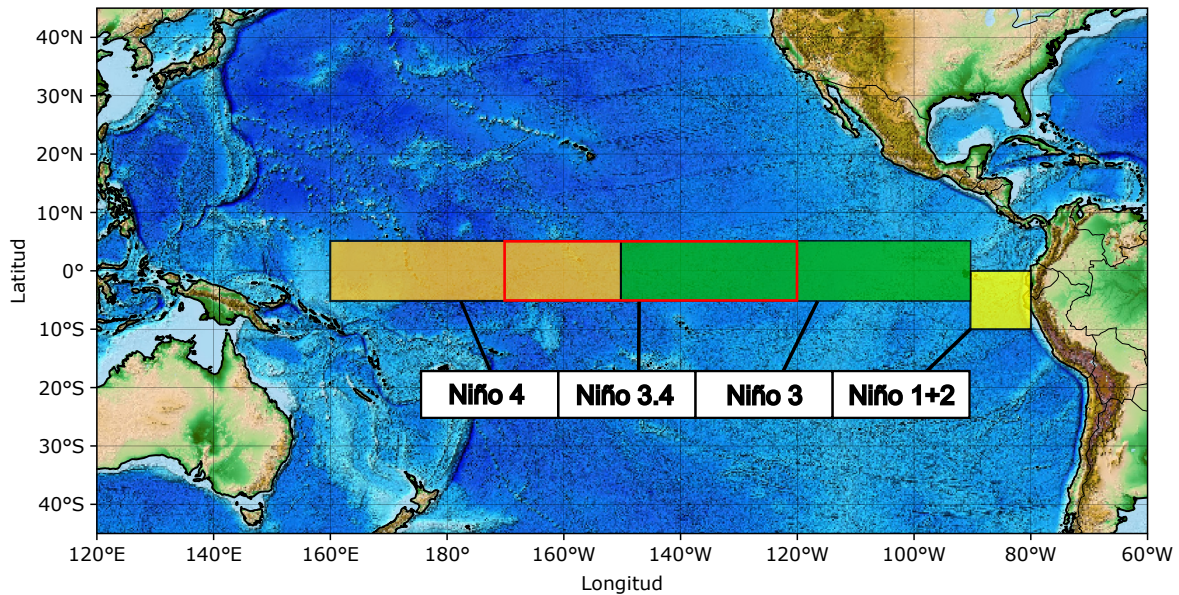


Figura 31: Ubicación espacial de las regiones Niño 1+2, Niño 3, Niño 4 y Niño 3.4 en el Pacífico Tropical

Fuente: Elaboración propia

3.2. DATOS

Desde El Niño extraordinario de 1997/98, se han creado o mejorado muchas reconstrucciones de observación y conjuntos de datos de reanálisis. A diferencia de los datos basados en estaciones o las observaciones puntuales “in situ” (por ejemplo, boyas y/o flotadores), estos conjuntos de datos grillados están completos tanto espacial como temporalmente y, para las reconstrucciones estadísticas de la TSM, se remontan a fines del siglo XIX. Varios centros orientados operativamente actualizan conjuntos de datos casi en tiempo real, lo que permite a los científicos monitorear el Pacífico tropical.

En la presente investigación se utilizaron varios tipos de información del periodo 1854-2022 y a nivel mensual, pudiendo clasificar los datos provenientes de información grillada y series de tiempo como: 1) Datos de la TSM grillada en las regiones Niño (Figuras 31 y 32), 2) Datos de Índices de Anomalías de TSM en las regiones Niño (Tablas 6 y 33) con ultimo acceso en 7 de julio de 2022.

Esta información será obtenida a partir de la data grillada de la National Oceanic Atmospheric Administration (*NOAA*) y los índices climáticos también serán del mismo portal.

Tabla 6: Índices climáticos utilizadas en este estudio

Nº	Índice
1	Niño 1+2
2	Niño 3.4
3	Niño 3
4	Niño 4

3.2.1. Datos de la TSM grillada en las regiones Niño

El conjunto de datos de la Temperatura Superficial del Mar Reconstruida y Ampliada (*ERSST*, en sus siglas en inglés) es un conjunto de datos de la TSM mensual global derivado del Conjunto Internacional Completo de Datos Océano-Atmósfera (*ICOADS*, en sus siglas en inglés). La versión de ERSSTv5 (Huang *et al.* 2017) es utilizada para esta investigación, es una cuadrícula de $2^{\circ} \times 2^{\circ}$ con una integridad espacial mejorada mediante métodos estadísticos. Estos datos mensuales comienzan en enero de 1854 hasta junio de 2022, la NOAA recomienda el uso de los datos partir enero de 1950, por ser data más confiables (Huang *et al.* 2017).

Esta versión más reciente de ERSST, la versión 5, utiliza nuevos conjuntos de datos de ICOADS Versión 3.0 de la TSM; la TSM proviene de flotadores ARGO de más de 5 metros del Hadley Center Ice-SST versión 2 (*HadISST2*, en sus siglas en inglés). ERSSTv5 ha mejorado la variabilidad espacial y temporal de la TSM al (a) reducir el filtrado espacial en el entrenamiento de las funciones de reconstrucción Teleconexiones Ortogonales Empíricas (TOE), (b) eliminar la amortiguación de alta latitud en los TOE, y (c) agregar 10 TOE más en el Ártico. ERSSTv5 mejoró la TSM absoluta al cambiar el uso de la temperatura del aire marino durante la noche como referencia a la TSM de boyas como referencia para corregir los sesgos de TSM de los barcos. Los científicos han mejorado aún más el ERSSTv5 mediante el uso de *First-Guess* no ajustado en lugar de *First-Guess* ajustado.




Figura 32: Producto ERSSTv5 NOAA-TSM en proyecciones Pseudo cilíndricas (Robinson). Los valores muestran la temperatura media mensual de 1854 – 2022

Fuente: Elaboración propia

<https://www.ncdc.noaa.gov/teleconnections/enso/indicators/sst>

3.2.2. Datos de los índices de anomalías de la TSM en las regiones Niño

A partir de la ERSSTv5 proveniente de Centro de Predicción del Clima (*CPC*, en sus siglas en inglés), se utiliza las anomalías ERSSTv5 NOAA en las regiones Niño, a continuación se detalla estos índices de anomalías.

Niño 1+2: El índice Niño 1+2 tiene la tendencia de mayor varianza con respecto a otros índices de ENOS (Figura 33b). Calculado a partir del ERSSTv5. Es el área promedio de la TSM de 0-10S y 90W-80W.

Niño 3: El índice de anomalías del Niño 3 (Figura 33d) captura anomalías de la TSM en el Pacífico ecuatorial central. Calculado a partir del ERSSTv5. Es el área promedio de la TSM de 5S-5N y 150W-90W.

Niño 4: El índice de anomalías del Niño 4 (Figura 33c), así como el índice de anomalía del Niño 3 captura anomalías de la TSM en el Pacífico ecuatorial central. Calculado a partir del

ERSSTv5. Es el promedio de la TSM del área de 5S-5N y 160E-150W.

Niño 3.4: Se puede considerar que el índice de anomalías de Niño 3.4 (Figura 33a) representan las TSM ecuatoriales promedio en todo el Pacífico desde aproximadamente la línea de fecha hasta la costa sudamericana. Calculado a partir del ERSSTv5, siendo el promedio de la TSM del área de 5S-5N y 170-120W.

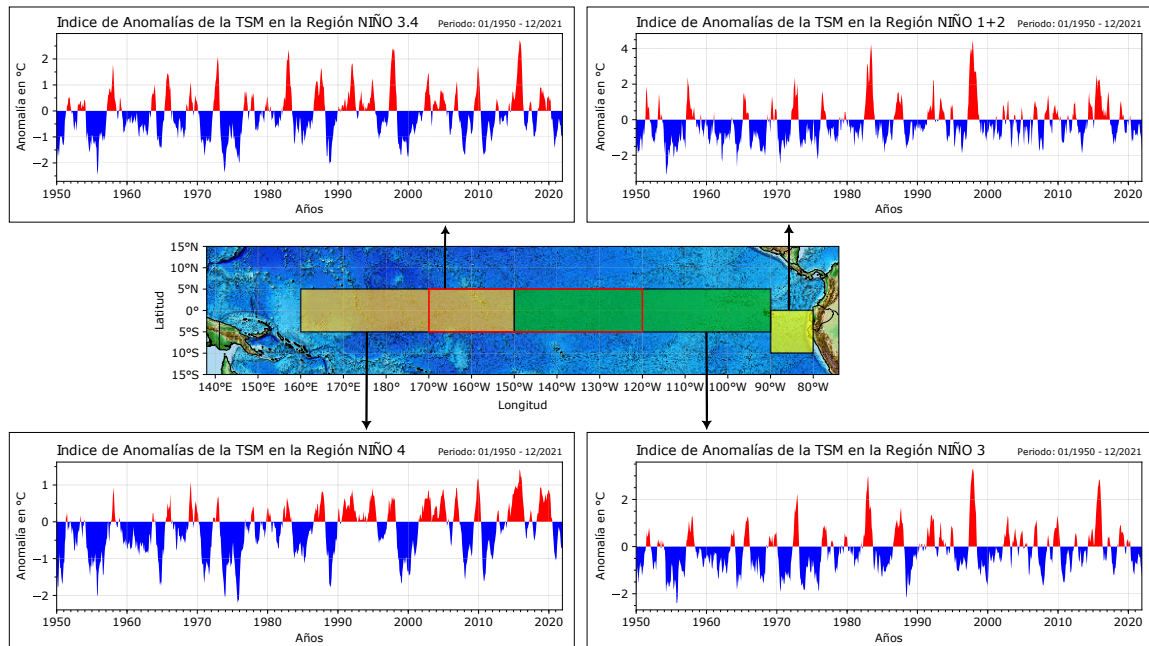


Figura 33: Índices de anomalías de las regiones: Niño 1+2, niño 3, niño 4 y niño 3.4 en el pacífico tropical

Fuente: Elaboración propia

3.3. METODOLOGÍA

A continuación, se presenta la metodología utilizada en esta investigación, con el fin de cumplir con los objetivos planteados, así mismo se muestra el esquema metodológico en la Figura 35, por lo cual, se describe cada uno de los procesos realizados en esta investigación:

3.3.1. Pre procesamiento de datos de la TSM

3.3.1.1. Recolección de datos de mapas cuadrículados espacios temporales de la TSM del pacifico tropical

Se usa data grillada de la TSM del producto ERSST v5 NOAA de enero de 1854 hasta junio de 2022 a nivel mensual, dividido en mapas de cuadrícula I*J basada en la longitud y latitud.

3.3.1.2. Normalización de la TSM en el área de estudio

Debido a la capacidad computacional con la que se cuenta en esta investigación, se define el área de estudio ubicado en latitud 10°S–10°N y longitud 140°E–80°W, en el pacífico tropical, el cual son parte de esta área de estudio las regiones Niño (Niño3, Niño3.4, Niño4 y Niño1+2).

Ahora ya seleccionado el área de estudio, se aplica técnicas de normalización a la data de la TSM. La técnica de normalización utilizada para estabilizar la convergencia de las funciones de pérdida de nuestra arquitectura de Red neuronal profunda, es la normalización min-max, esto para los datos de entrenamiento, se muestra a continuación la ecuación:

$$X_{i \text{ norm}} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \in [0, 1] \quad (14)$$

Donde:

$X_{i \text{ norm}}$: El i-ésimo valor normalizado en el conjunto de datos de la TSM.

X_i : El i-ésimo valor en el conjunto de datos de la TSM.

X_{min} : Valor mínimo del conjunto de datos de la TSM.

x_{max} : Valor máximo del conjunto de datos de la TSM.

3.3.2. Creación y elección de la arquitectura del modelo de red neuronal profunda CONVLSTM

Para la obtención y pronóstico más próximo a los datos reales de la TSM se usaron métricas estadísticas para las etapas de entrenamiento (calibración) y validación, se seleccionó el mejor ajuste y la arquitectura más óptima de una red neuronal profunda (Figura 36) para el pronóstico de ENOS. La idea de elegir un modelo es que capture las dependencias espacio temporales en horizontes de tiempo más largos (igual o más de 6 meses), debido a que las interacciones del sistema climático global del océano-atmósfera, no solo están relacionadas con el aspecto temporal sino se debe modelar también la relación espacial de los vecinos en cualquier región seleccionada.

El conjunto de datos normalizados de la TSM se ingresa en la red de aprendizaje profunda para su posterior pronóstico, a continuación, se detalla la creación del modelo.

Aquí el modelo elegido es ConvLSTM (Figura 36), el cual es parte de dos modelos CNN y LSTM, las CNN se usan para la extracción de características espaciales, las LSTM se usan para el pronóstico de secuencias temporales. ConvLSTM es un tipo de red neuronal recurrente para la predicción espacio-temporal que tiene estructuras convolucionales tanto en las transiciones de entrada a estado como de estado a estado. El ConvLSTM determina el estado futuro de una determinada celda en la cuadrícula por las entradas y los estados pasados de sus vecinos locales (Shi *et al.* 2015). Esto se puede lograr fácilmente mediante el uso de un operador de convolución en las transiciones de estado a estado y de entrada a estado (Figura 36). Las ecuaciones clave e importantes de ConvLSTM se muestran a continuación:

$$g_t = \tanh(W_{xg} * X_{t+1} + W_{hg} * H_{t-1} + b_g) \quad (15)$$

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \quad (16)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f) \quad (17)$$

$$C_t = f_{ci} \odot C_{t-1} + i_t \odot g_t \quad (18)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \odot C_{t-1} + b_o) \quad (19)$$

$$h_t = o_t \odot \tanh(c_t) \quad (20)$$

Donde:

i_t representa la puerta de entrada, f_t representa la puerta de olvido, o_t representa la puerta de salida, g_t representa la puerta de modulación de entrada, C_t representa el estado del momento actual, C_{t-1} representa el estado del momento anterior, h_t representa la salida final, W representa el coeficiente de ponderación para una puerta dada, b representa el coeficiente de polarización correspondiente para una puerta dada.

$\sigma = \frac{1}{1+\epsilon^{-x}}$: es la función de activación sigmoïdal.

* $y \odot$: Denota el operador de convolución y el producto de Hadamard respectivamente.

3.3.3. Entrenamiento (calibración) y validación de datos de la TSM

Se utilizó el 85 por ciento de datos (enero de 1854 a diciembre 1996) seleccionados anteriormente para su entrenamiento (calibración) del modelo, así mismo se utilizó el 10 por

ciento de datos (enero de 1997 a diciembre 2013) para validación del modelo, dejando para la prueba (test) un 5 por ciento de datos restantes (enero de 2014 a junio de 2022), estos datos del test no fueron utilizados ni en entrenamiento ni en validación, solo se usará para pronóstico de ENOS futuros.

Se muestra en la Figura 34, el rango de datos utilizados en esta investigación en entrenamiento, validación y prueba (test, datos no utilizados).



Figura 34: Rango de datos de esta investigación

Para el modelo de Red Neuronal Profunda ConvLSTM, en etapa de entrenamiento y validación, se utiliza la métrica estadística recomendada por la inteligencia artificial denominado Error Cuadrático Medio (MSE).

3.3.4. Modelo de pronóstico de la TSM espacio temporal

Una vez elegido el modelo óptimo, entrenado y validado, se desnormalizará la TSM para obtener mapas espacio temporales de TSM y anomalías de la TSM en las regiones Niño.

3.3.4.1. Pronóstico y evaluación de la TSM y anomalías de la TSM espacio temporal con El Niño Extraordinario de 1982/1983 y 1997/98.

Se pronosticará mapas grillados de la TSM y anomalías de la TSM espacio temporales de la región Niño de los meses que correspondan a los años Niño Extraordinario 1982/83 y 1997/98, y se comparará con los datos observados.

3.3.4.2. Pronóstico de la TSM y anomalías de la TSM espacio temporal de eventos El Niño en diferentes horizontes de tiempo en etapa de test

Se pronosticará mapas grillados de la TSM y anomalías de la TSM espacio temporal de una región Niño (por ejemplo: Niño 3.4 y Niño 1+2) con muchos meses de anticipación (a largo plazo) de años ENOS (Niño o Niña) y se comparará con los meses de eventos ENOS (por ejemplo, El Niño 2015/16), todo esto para ver el grado de exactitud del pronóstico, mediante

las métricas estadísticas.

Para evaluar el rendimiento del modelo en etapa de test y pronóstico de las anomalías de la TSM observada y pronosticada, se utilizan métricas estadísticas recomendadas por la inteligencia artificial, las cuales se detallan a continuación:

Se utilizan las tres métricas estadísticas de escala como el MSE, RMSE y el MAE, todas estas métricas estadísticas serán más óptimos y eficientes cuando el valor sea menor.

También se utilizan dos métricas estadísticas porcentuales como el RMSPE y el MAPE, esto para su evaluación y clasificación de acuerdo a lo mencionado por Armstrong y Collopy (1992) y Sanders (1997) mostrado en las Tablas 4 y 5.

Para el pronóstico de ENOS se enfoca en el área de latitud 10°N-10°S y longitud 140°E-80°W (Figura 31), debido al concepto de ENOS mencionado por la WMO (2014) descrito en esta investigación en la sección 2.2.2. Posteriormente para el análisis y pronósticos se enfocan en regiones Niño específicas como la región Niño 3.4 y Niño 1+2 (Figura 31), esto sustentado con información científica en los siguientes párrafos.

La región Niño 3.4 según la NOAA es considerada el área y ubicación principal para monitorear y pronosticar ENOS, así mismo la mayoría de centros operativos e investigaciones de la evolución de ENOS se dan en la región Niño 3.4 (por ejemplo, Administración Meteorológica de Japón (JMA), Centros Nacionales de Predicción Ambiental (NCEP), Administración Meteorológica de Korea (KMA), Oficina de Meteorología del Gobierno de Australia (BoM). Con el pasar del tiempo y el desarrollo de estudios científicos, se llegó a la conclusión que el área en la región Niño 3.4 es la que mejor representa la condición de El Niño y La Niña (Barnston 1997; L'Heureux *et al.* 2013; Tippett y L'Heureux 2020).

Sin embargo, para algunos países del mundo como por ejemplo la costa del Perú y Ecuador, los cambios que ocurren de las condiciones oceánicas y atmosféricas en la región Niño 1+2 son iguales o más representativos que los de la región Niño 3.4 (Takahashi 2017; Ramírez y Briones 2017). Por todo lo mencionado anteriormente, se concluye que nuestra área de

estudio localizada son las regiones Niño 3.4 y Niño 1+2.

ENOS se caracteriza por anomalías en la TSM en el Pacífico tropical y se identifica principalmente con índices climáticos (por ejemplo, Niño 3.4, Niño 1+2, ONI, ICEN). El pronóstico ENOS de esta investigación se formula como un problema de pronóstico de secuencia espacio temporal en el que tanto la entrada como la salida son secuencias de la TSM (Dijkstra *et al.* 2019; Guo *et al.* 2020; Petersik y Dijkstra 2020), posteriormente se puede comparar mediante índices Niño 3.4 y Niño 1+2, que también se puede obtener en función de la salida obtenida que es la TSM.

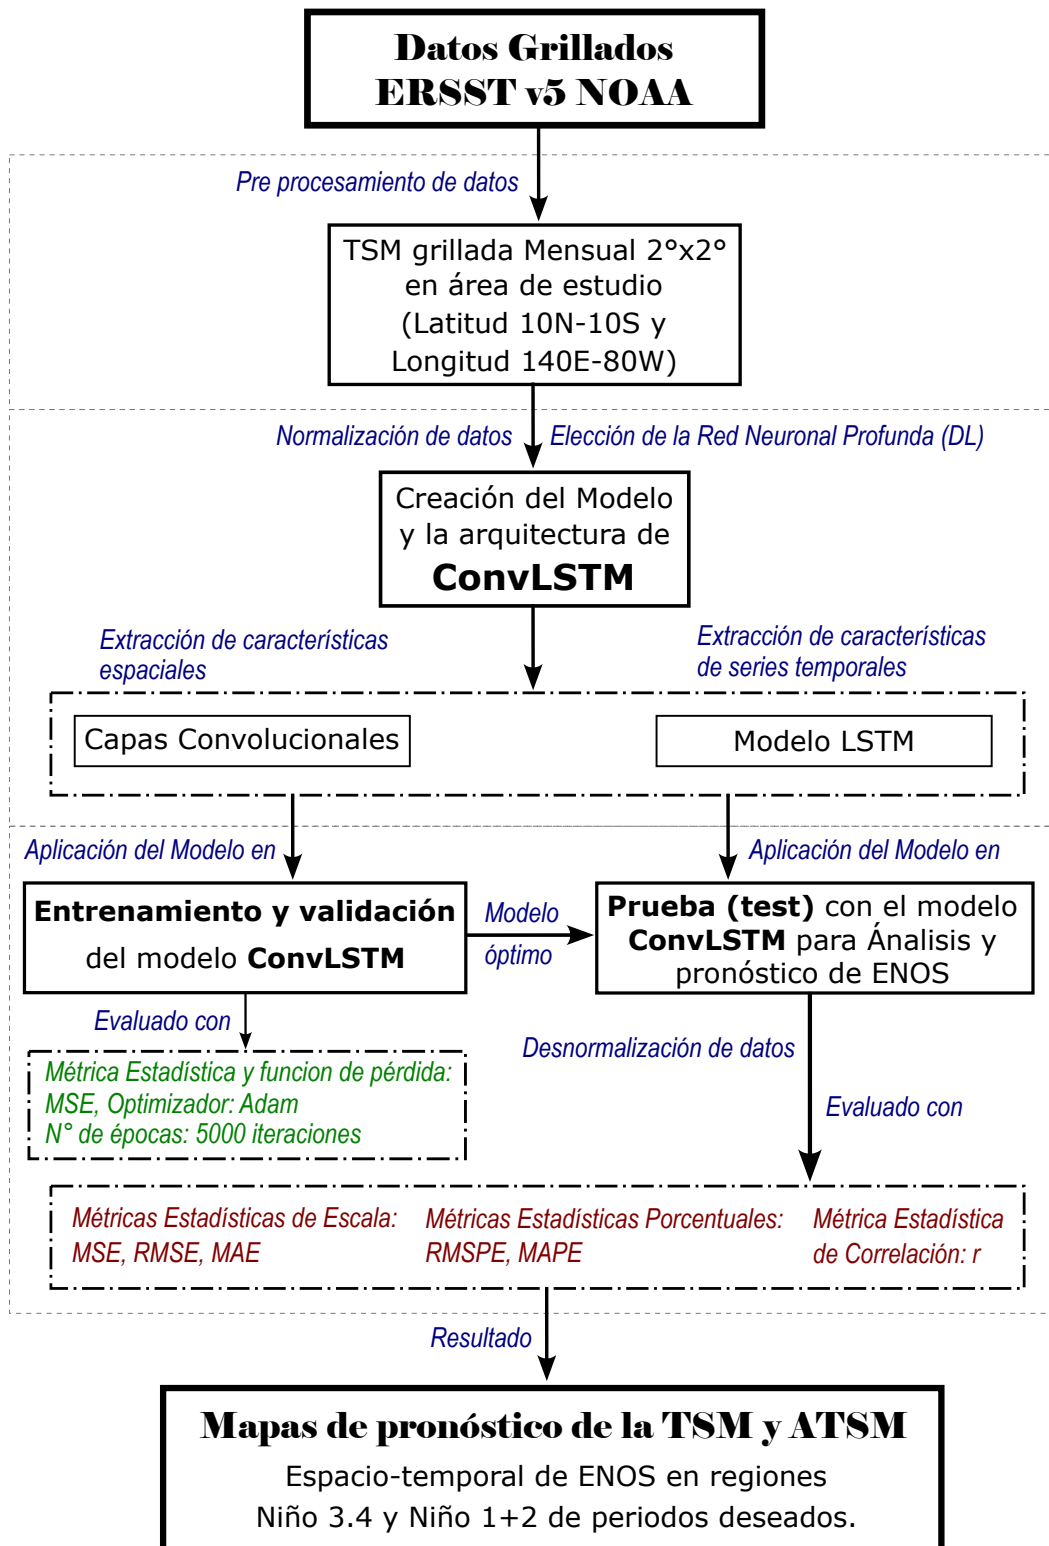


Figura 35: Esquema metodológico de la investigación

Fuente: Elaboración propia

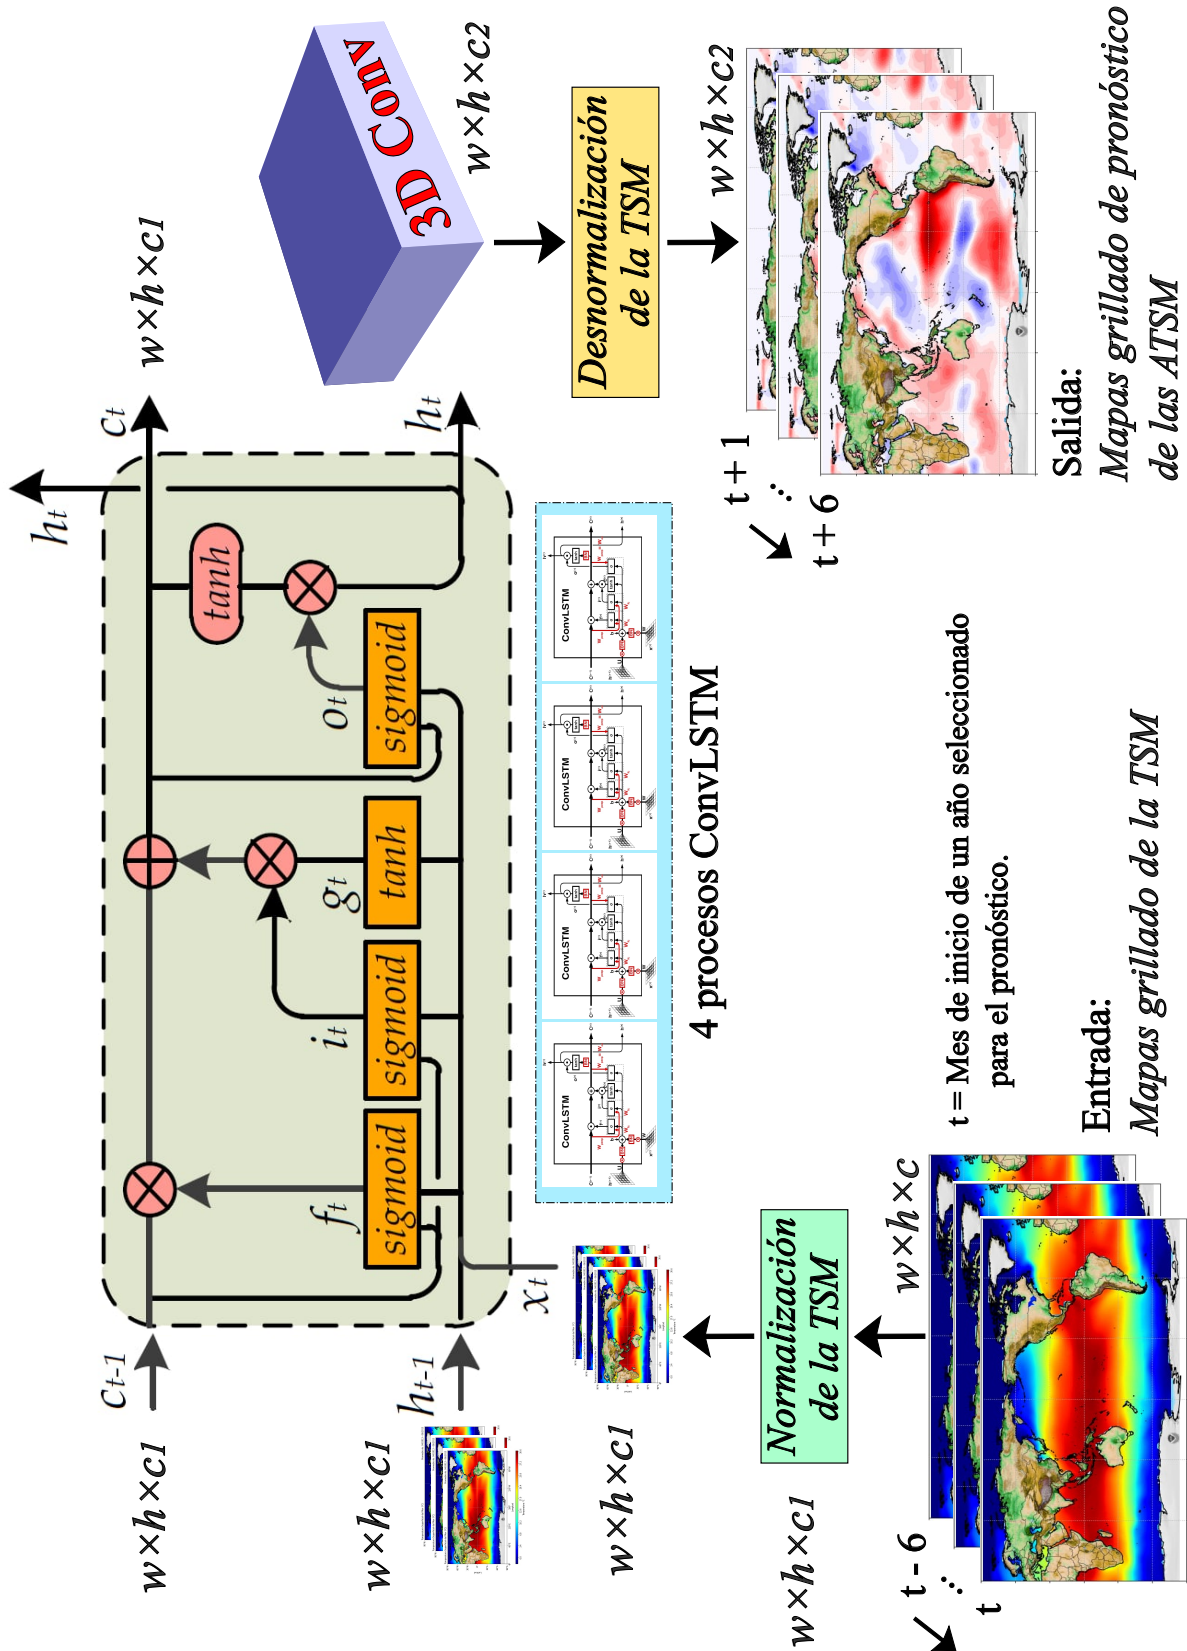


Figura 36: Modelo conceptual de la red neuronal profunda utilizada en el pronóstico del ENOS de esta investigación

Fuente: Elaboración propia

IV. RESULTADOS Y DISCUSIÓN

Los resultados y discusión están dados en función de los objetivos específicos planteados: i) resultado de un modelo de red neuronal profunda, que integra la memoria convolucional a corto y largo plazo (ConvLSTM), ii) resultado de verificar el modelo de red neuronal profunda para pronósticos El Niño extraordinario, iii) resultado de calcular y pronosticar anomalías de la temperatura superficial del mar de las regiones Niño 3.4 y Niño 1+2, mediante la red neuronal profunda y iv) resultado de comparar y evaluar el modelo de red neuronal profunda con modelos dinámicos y estadísticos globales.

En esta investigación se sigue la siguiente lógica para mostrar los resultados, iniciando con describir y explorar los datos y observaciones, seguido de explicar el modelo conceptual y posteriormente predecir escenarios de ENOS, con el fin de controlar e intervenir en la toma de decisiones técnicas y políticas.

4.1. DESCRIPCIÓN Y EXPLORACIÓN DE DATOS

Primeramente, se comienza con la exploración de datos de la TSM y su evolución de los eventos ENOS en las regiones Niño y en el tiempo.

4.1.1. Exploración y análisis de datos de eventos ENOS

Se genera mapas grillados globales de la TSM y anomalías de la TSM de distintos eventos ENOS para su exploración y análisis de los datos. Este proceso permitió analizar el comportamiento de la TSM y anomalías de la TSM durante los diferentes meses del periodo de datos disponible (1854 – 2022), en diferentes eventos ENOS.

En 1982 se tuvo un calentamiento progresivo del Océano Pacífico entre los 5°S y los 20°S acompañó el debilitamiento del anticiclón del Pacífico Sur. Esto provocó una disminución

simultánea de los alisios del sureste en el área del Pacífico oriental, lo que permitió un desplazamiento prematuro de la zona de convergencia intertropical (ZCIT) en el Pacífico norte más cerca del ecuador durante septiembre de 1982 (Kerr 1983). El evento Niño Extraordinario de 1982/83 dentro de los meses de mayor evolución que fue de diciembre a febrero, el incremento mayor de la TSM (Figura 37a) se concentra en toda la región central y oriental del pacifico ecuatorial, con valores de anomalías que superan los 4°C (Figura 37b), así mismo se observa TSM ecuatoriales superiores a 28°C en la región central y oeste del pacifico ecuatorial (Figura 37a).

Respecto al evento Niño Extraordinario 1997/98, se inició con una convección tropical anormal sobre el Pacífico oriental y vientos más fuertes del oeste en las latitudes medias bajas de ambos hemisferios, este El Niño muestra características típicas de la fase madura (o más fuerte) de los episodios cálidos. (NOAA, 1998).

Las condiciones del episodio cálido dominaron en el Pacífico tropical durante diciembre de 1997 a enero de 1998, con TSM superiores a 28°C en la mayor parte del Pacífico ecuatorial (Figura 38a). Las anomalías de la TSM excedieron +1°C en todo el Pacífico ecuatorial al este de la línea de fecha (180° en longitud) y excedieron los +5°C al este de 120°W (Figura 38b). Dentro de la región Niño 3, las anomalías de la TSM aumentaron marginalmente de 3.7°C a 3.9°C por encima de lo normal en noviembre de 1997.

En contraste, La Niña 1998/99, considerada Niña Fuerte (según ONI), sucedió posteriormente al finalizar el evento Niño extraordinario 1997/98, dándose el decremento de la TSM, solo en la región central del pacifico ecuatorial (Figura 39a), con valores de anomalías inferiores a los -1.5°C (Figura 39b), así mismo, se observa TSM ecuatoriales inferiores a 20°C en la región central y este del pacifico ecuatorial.

La Figura 40b se ilustra la evolución de las anomalías de la TSM asociadas con La Niña Fuerte del 2010 en el Océano Pacífico. El enfriamiento inicial apareció en el Pacífico ecuatorial del este al Pacífico ecuatorial central alrededor de junio de 2010 y se convirtió en un evento de La Niña relativamente fuerte a fines de 2010. El evento persistió más allá de febrero de 2011.

La Niña Fuerte 2010 (basado en ONI), en los meses de octubre a diciembre (meses de mayor evolución de la Niña Fuerte), se da un decremento de la TSM, en la región central y oriental del pacífico ecuatorial (Figura 40a), con valores de anomalías inferiores a los -1.5°C (Figura 40b), así mismo, se observa TSM ecuatoriales inferiores a 18°C en la región central y este del pacífico ecuatorial (Figura 40a).

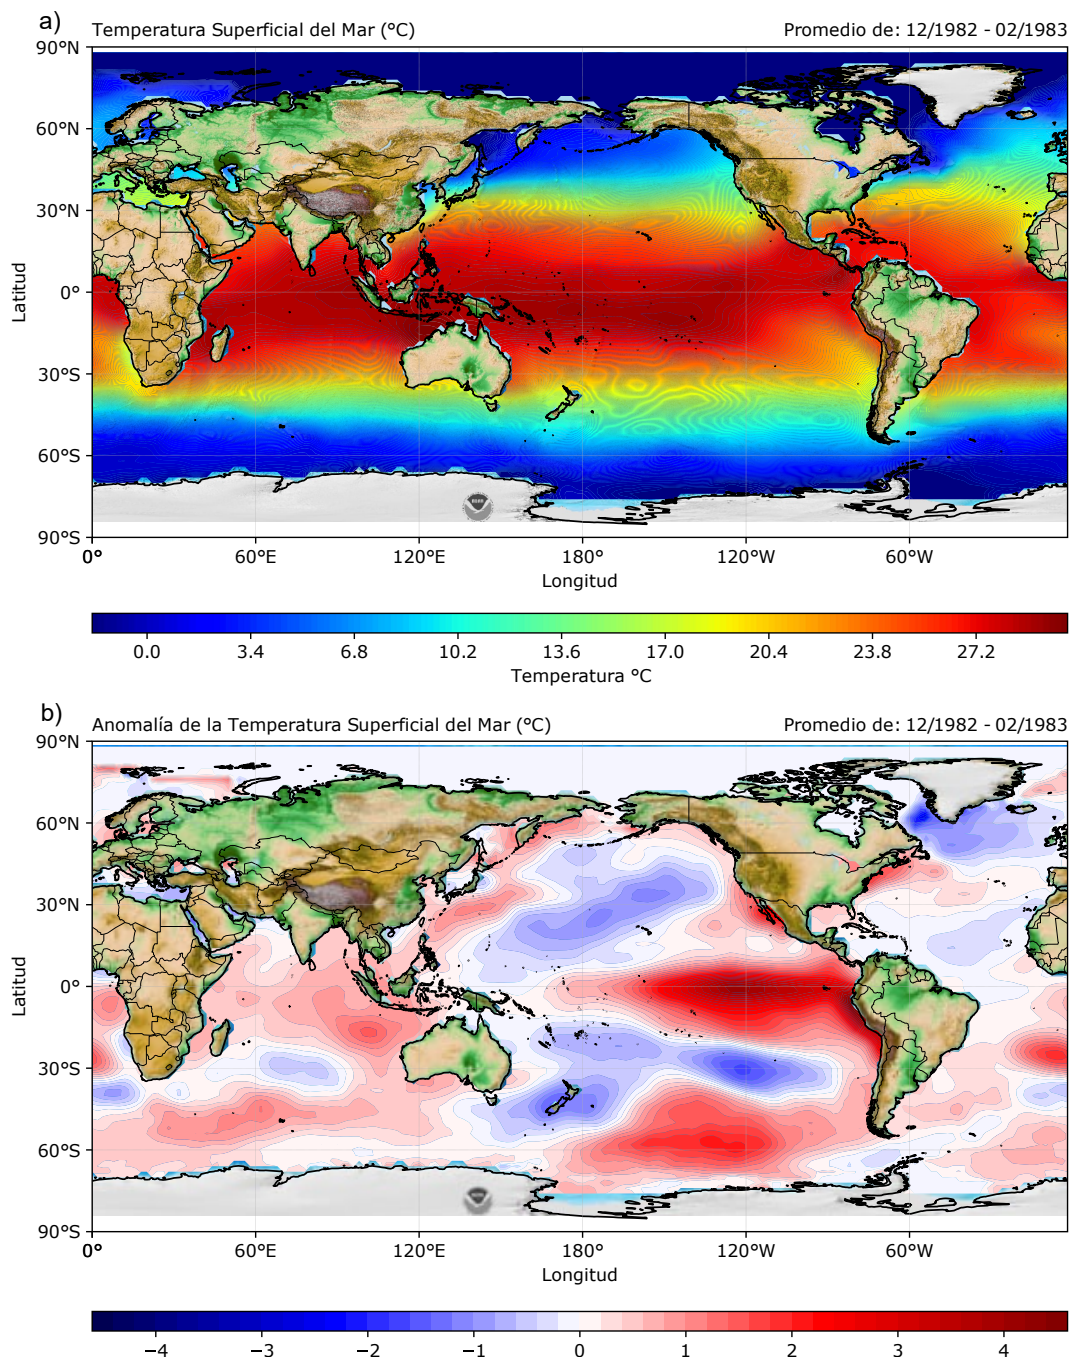


Figura 37: Promedio de la TSM de diciembre a febrero de 1982/83, b) Anomalías de la TSM de diciembre a febrero de 1982/83.

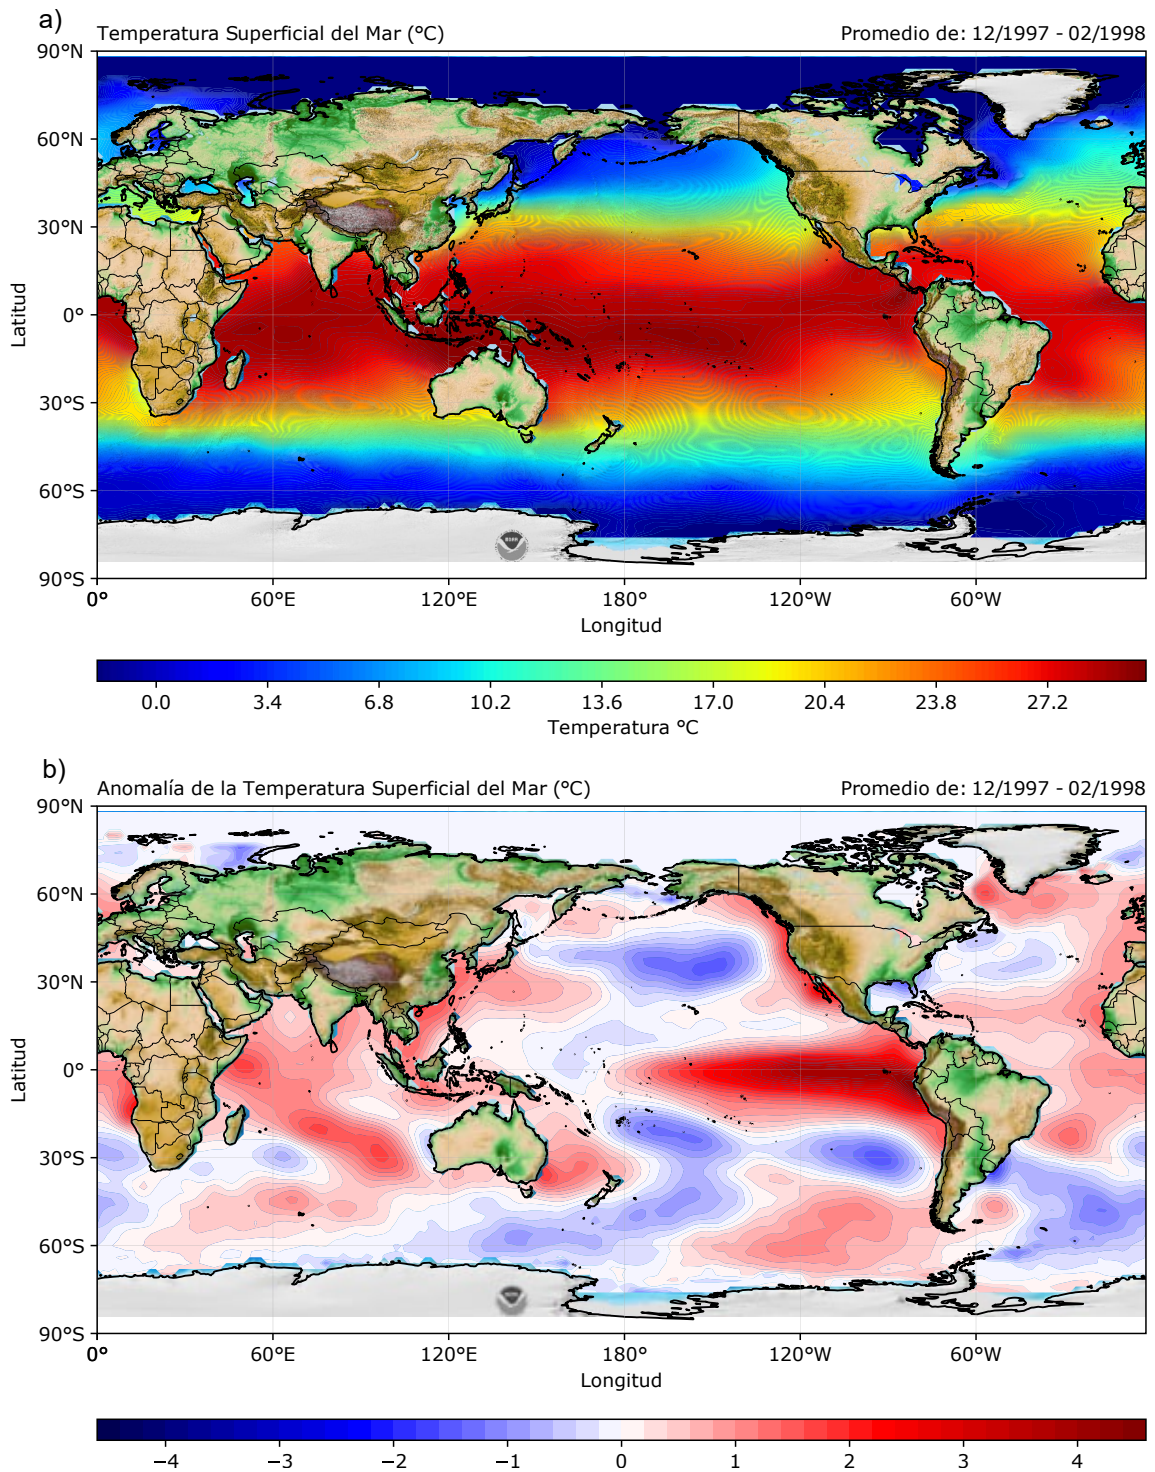


Figura 38: a) Promedio de la TSM de diciembre a febrero de 1997/98, b) Anomalías de la TSM de diciembre a febrero de 1997/98

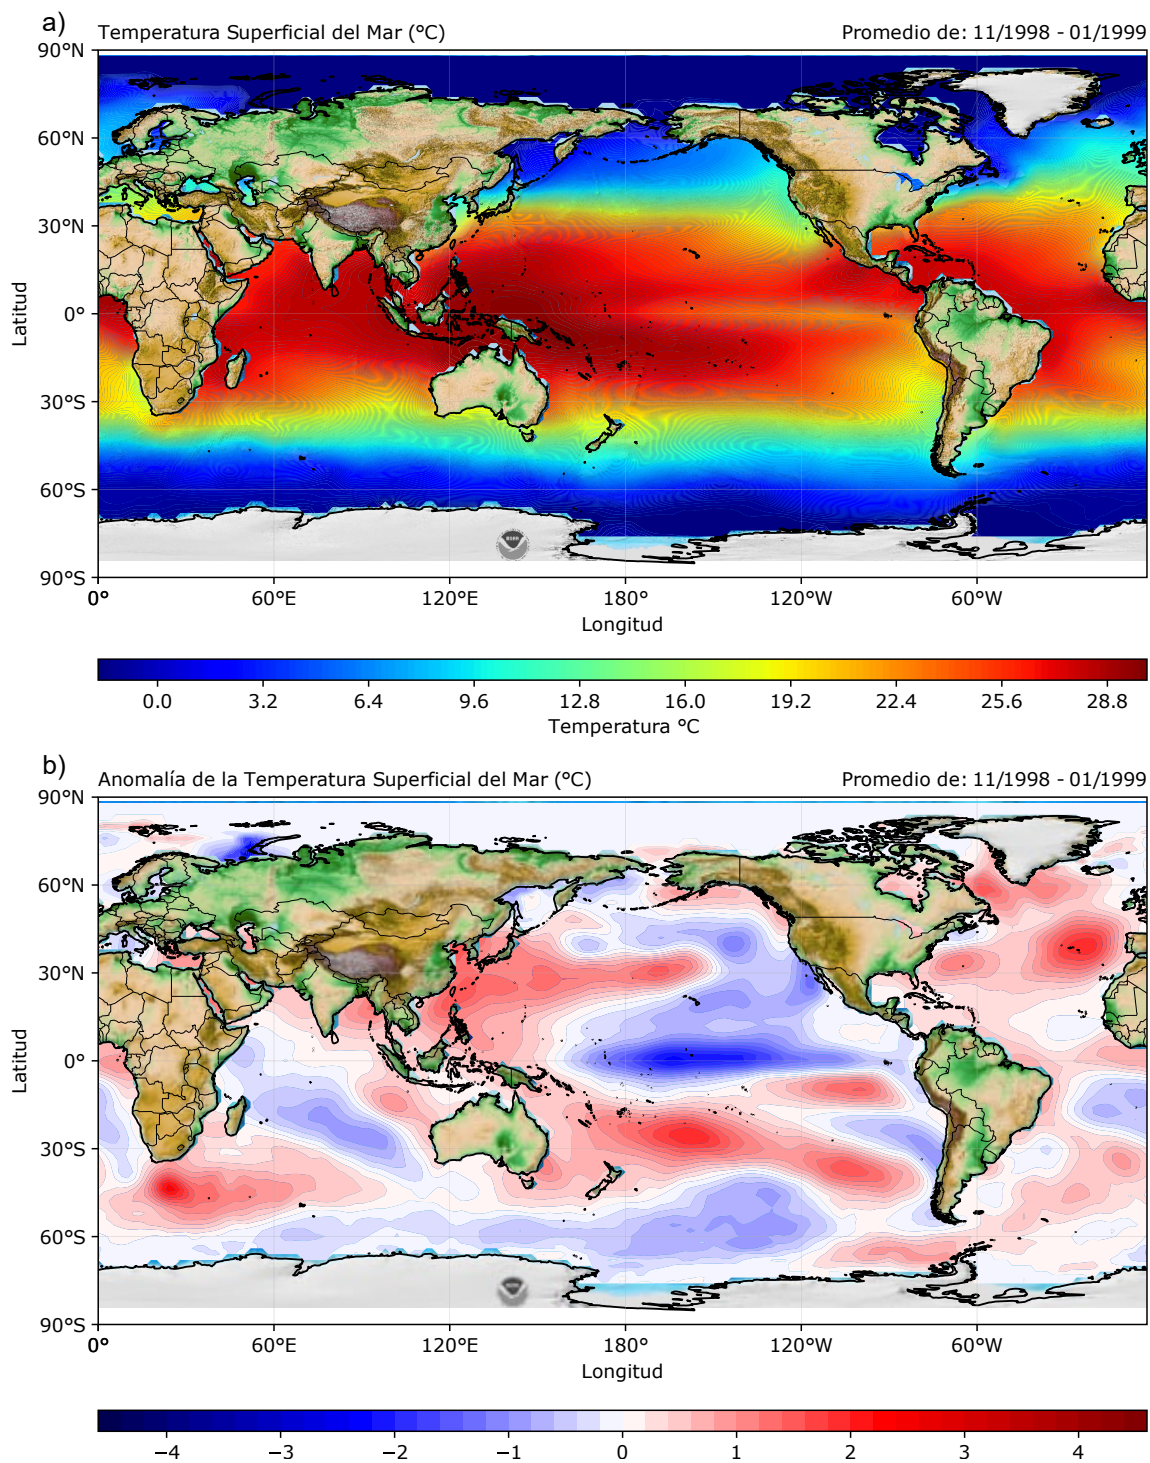


Figura 39: a) Promedio de la TSM de noviembre a enero de 1998/99, b) Anomalías de la TSM de noviembre a enero de 1998/99

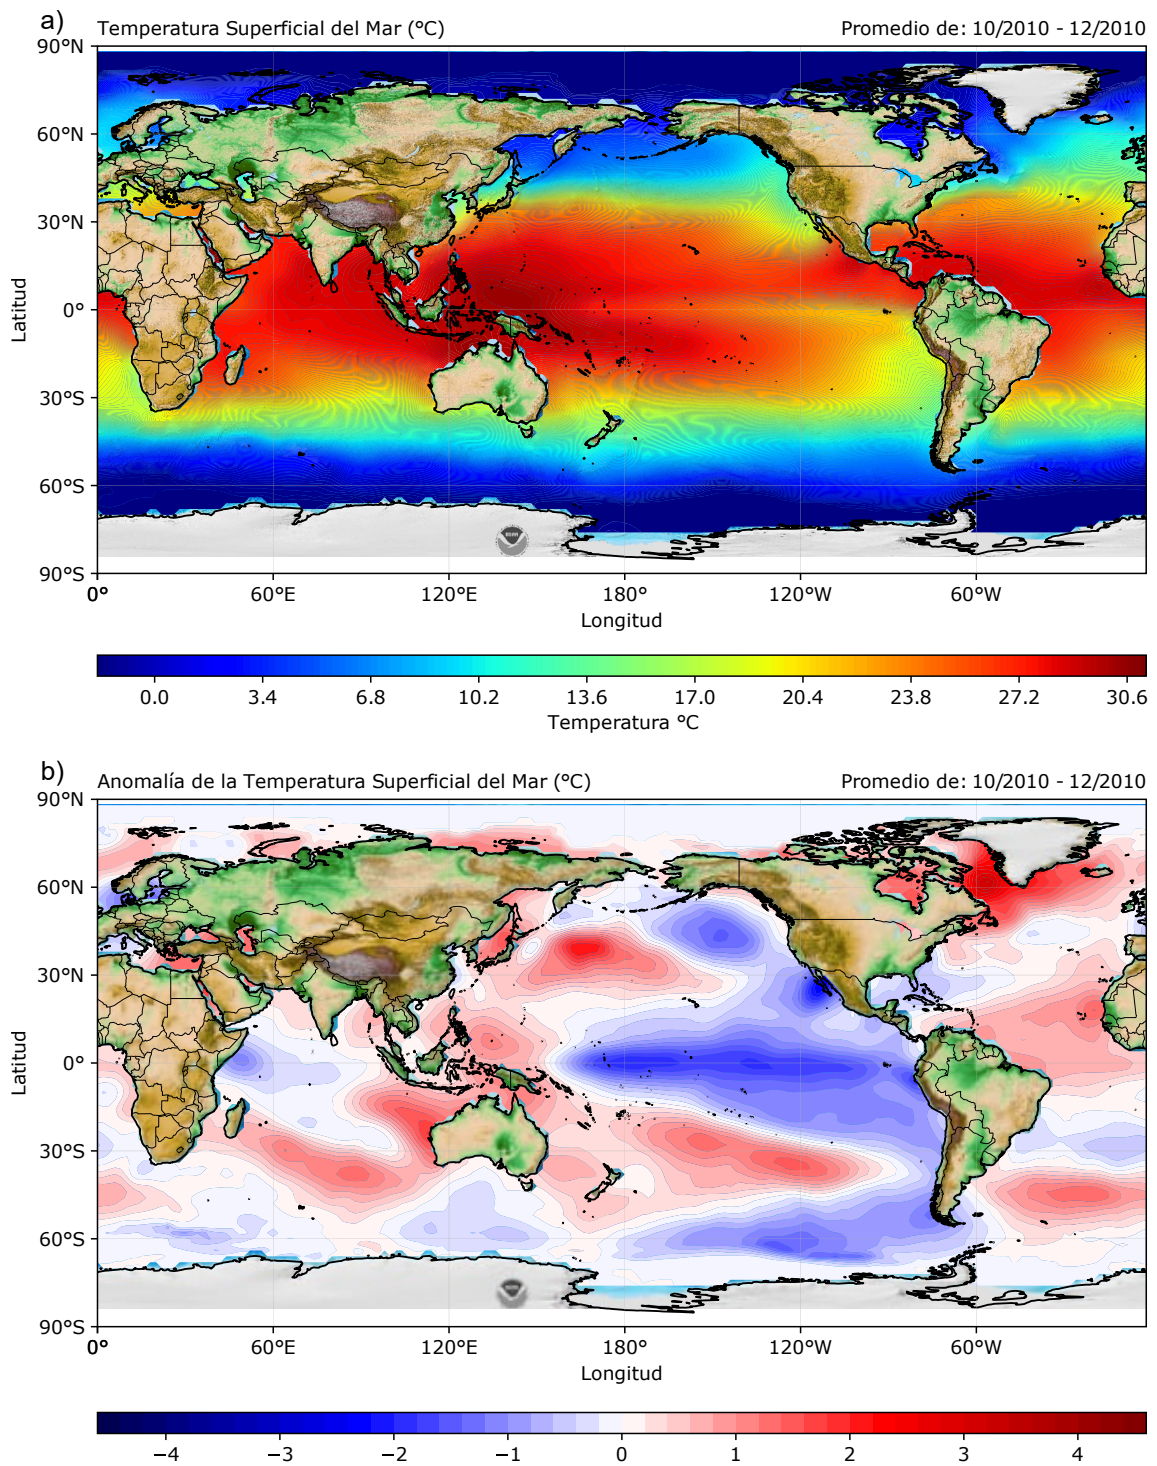


Figura 40: a) Promedio de la TSM de octubre a diciembre del 2010, b) Anomalías de la TSM de octubre a diciembre del 2010

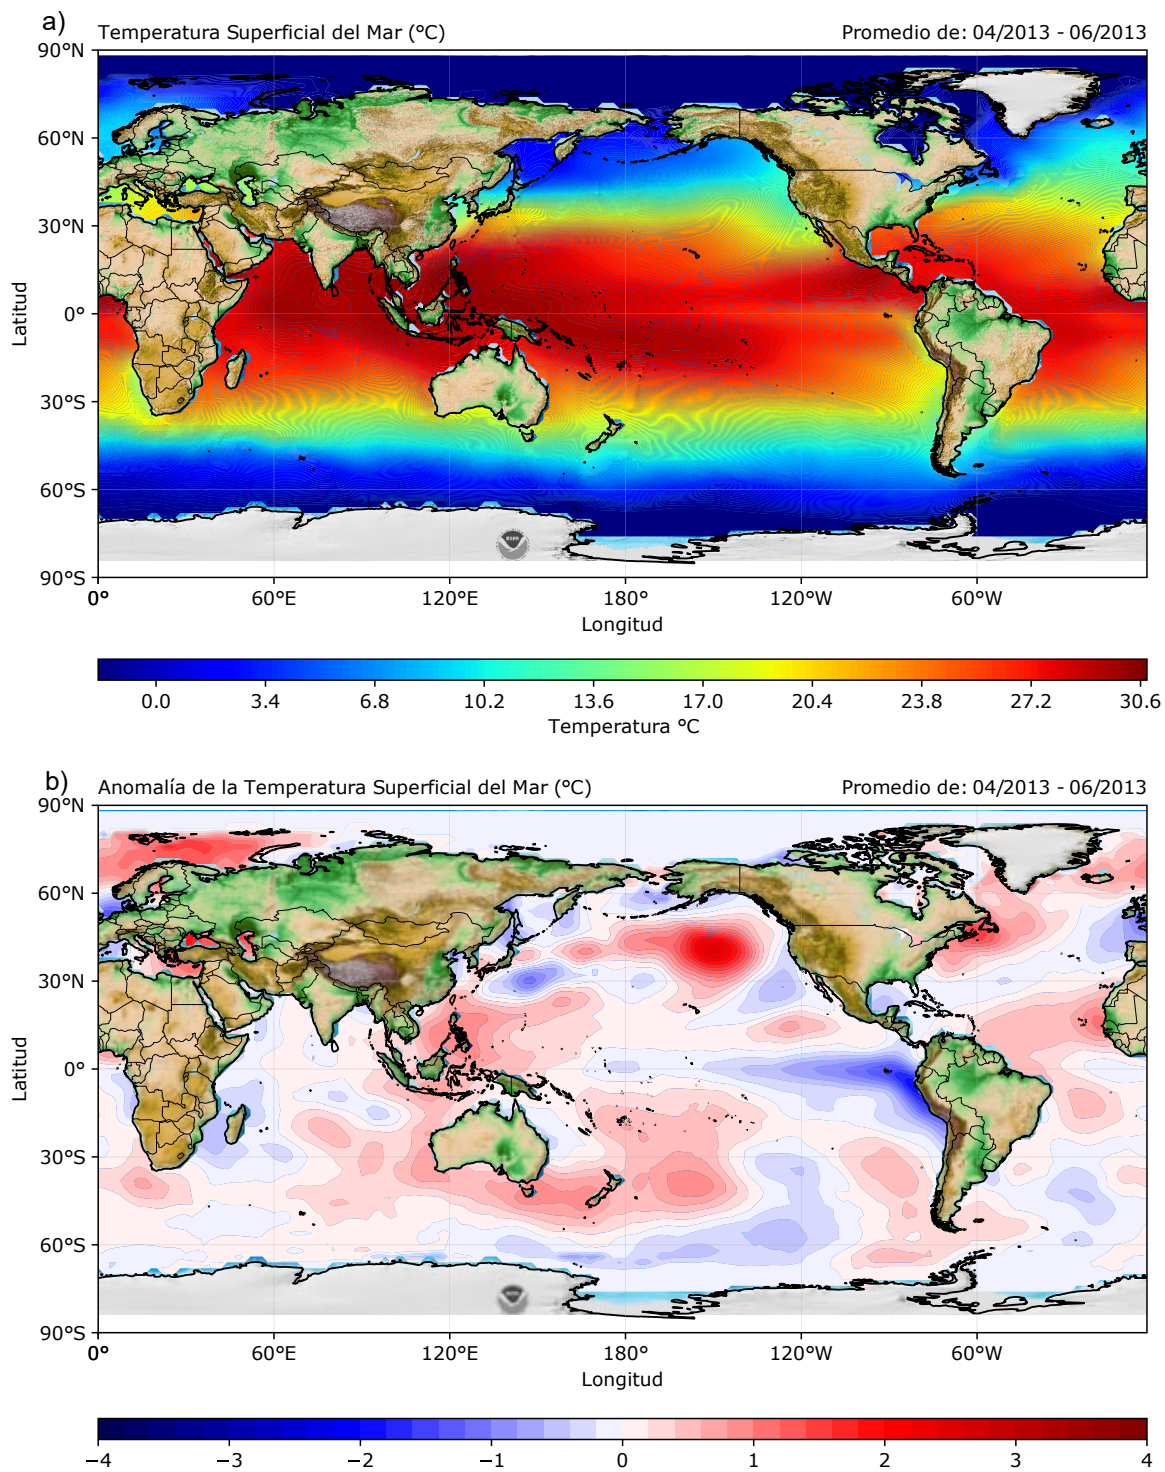


Figura 41: a) Promedio de la TSM de abril a junio del 2013, b) Anomalías de la TSM de abril a junio del 2013

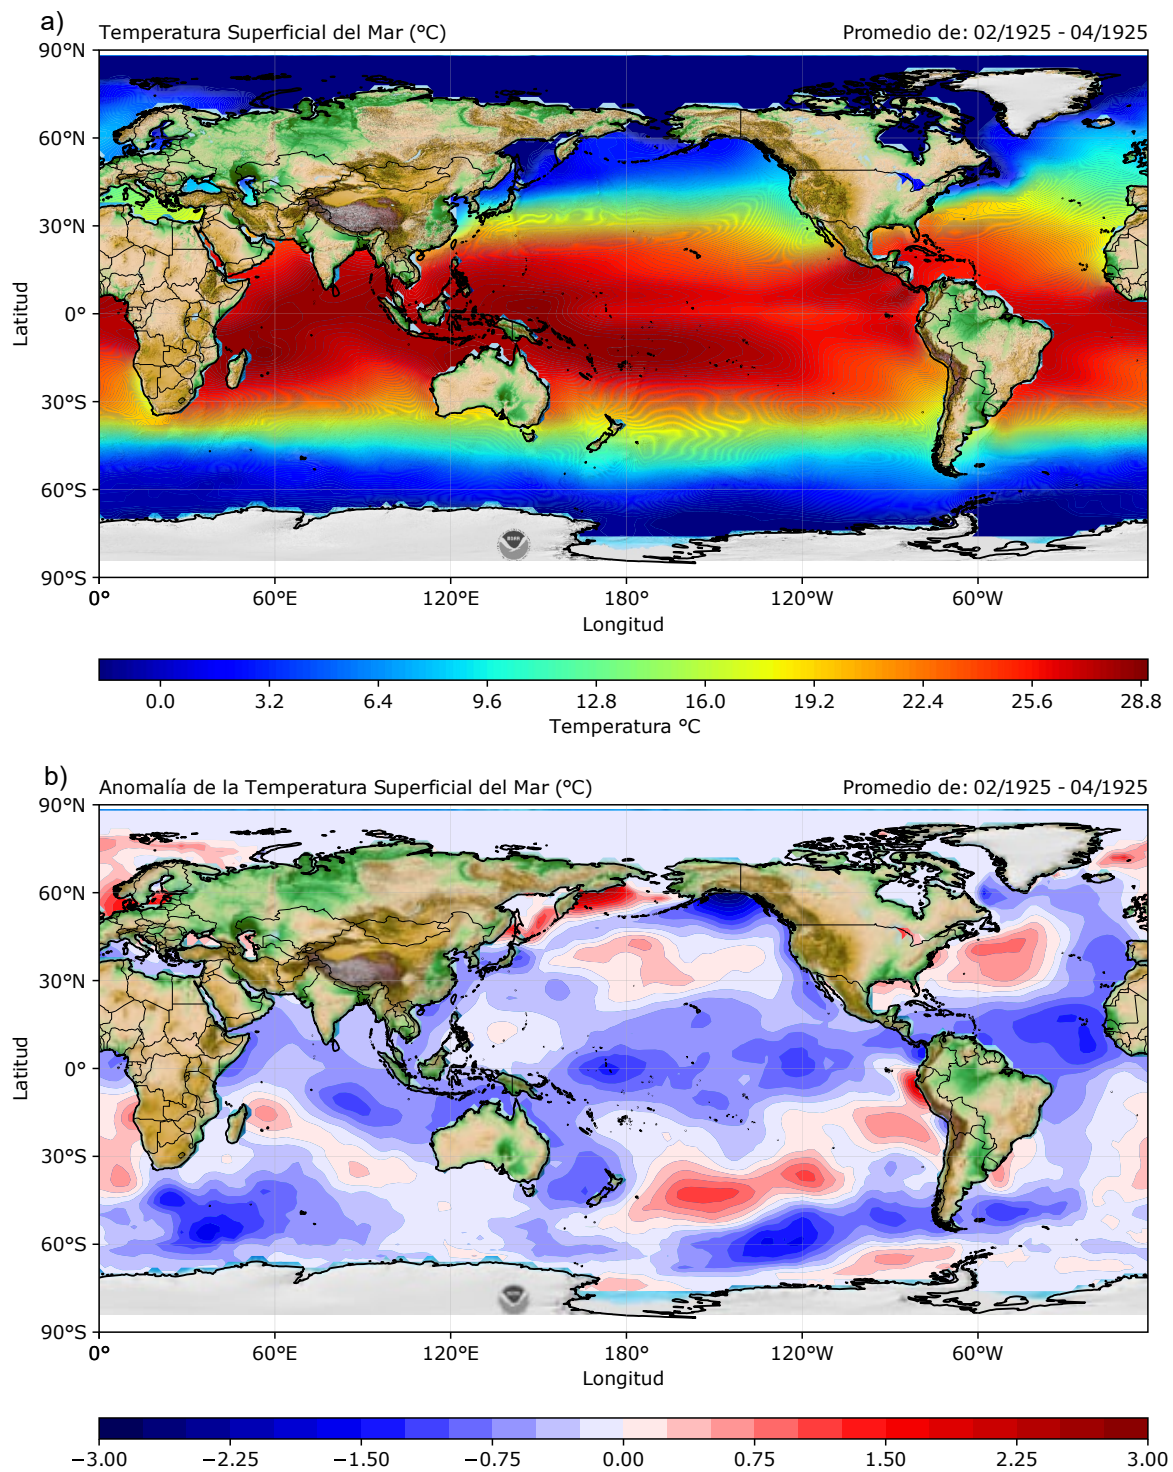


Figura 42: a) Promedio de la TSM de febrero a abril de 1925, b) Anomalías de la TSM de febrero a abril de 1925

El evento La Niña Fuerte 2013, fue muy diferenciado a los eventos antes mencionados, ya que, presenta un decremento de la TSM solo en la región oriental del pacifico ecuatorial, con valores de anomalías inferiores a los -1.4 °C (Figura 41b), así mismo, se observa TSM

ecuatoriales inferiores a 15°C solo en la región oriental del pacífico ecuatorial (Figura 40a).

El Niño costero de 1925, fue uno de los más fuertes del siglo XX según sus impactos en la costa sudamericana asociados a intensas lluvias (Takahashi y Martínez 2019), es por ello que es necesario que el modelo ConvLSTM reconozca este evento, por lo tanto, se gráfica el evento En Niño Costero de 1925 (Figura 42a y 42b), el cual solo presenta anomalías de la TSM en la pacífico oriental (Figura 42b) con valores de anomalías superiores a 2°C así mismos, se observa TSM ecuatoriales de 19°C solo en la región oriental del pacífico ecuatorial (Figura 42a).

4.1.2. Exploración de datos temporal y espacial (longitud y latitud promedio) en la región de estudio (latitud 10°S–10°N y longitud 140°E–80°W)

Con el objetivo de explorar y analizar la variabilidad temporal y espacial (longitud) y el comportamiento de la TSM del pacífico ecuatorial, se generaron perfiles o diagramas longitud – tiempo denominadas Hovmöller, promedio de la latitud 10°S–10°N, se muestra desde la longitud 140°E–80°W. Para ello se utilizaron datos de anomalías de la TSM.

La evolución del ENOS en sus dos fases El Niño y La Niña, tienen un comportamiento complejo y diferente en su componente temporal como espacial (Figura 43, 44 y 45), se inicia mostrando la evolución del Niño Extraordinario 1982/83 y 1997/98 (Figura 43), el caso del Niño 1982/83 (Figura 43a) se muestra las anomalías de temperatura positivas iniciando en octubre del 1982 en las regiones Niño 1+2, Niño 3, Niño 4 y Niño 3.4 hasta abril de 1983, y posteriormente continuando las anomalías positivas de temperatura solo en la región niño 1+2 (Pacífico Este) desde abril de 1983 hasta agosto de 1983 (Figura 43a), para el caso del niño extraordinario 1997/98 (Figura 43b) se muestra anomalías positivas de temperatura desde junio del 1997 hasta mayo del 1998 en las regiones niño 1+2, niño 3, niño 3.4 y niño 4, concluyendo que para ambos eventos de Niño Extraordinario 1982/83 y 1997/98, no tiene el mismo comportamiento temporal de anomalías de temperatura, cada Niño Extraordinario es particular en su evolución con respecto a la TSM.

En el caso de la fase La Niña, se muestra el evento La niña Fuerte 1998/99 (Figura 44a) y La niña Fuerte 2010/11 (Figura 44b), el cual es considerado como Niña Fuerte, en la

Figura 44a se muestra anomalías negativas de temperatura solo en el pacífico central (región Niño 3.4 y Niño 4), desde julio de 1998 hasta abril del 1999, mas no en el pacífico este, se muestra ahí anomalías positivas de temperatura (Figura 44a), se observa también que este evento es precedido del evento El Niño Extraordinario 1997/98, en la Figura 44b nos muestra un evento Niña Fuerte, mostrando anomalías negativas de temperatura en la región Niño 4, Niño 3.4, Niño 3 y Niño 1+2, desde mayo de 2010 hasta febrero del 2011; entre enero del 2011 hasta abril del 2011 en la región Niño 1+2 se observa anomalías positivas de temperatura moderadas, se observa también que este evento es precedido del evento El Niño Moderado 2009/10.

Cabe recordar que las fases de ENOS no tienen la misma evolución espacial y temporal, claro está mencionar el evento La Niña 2007, catalogado como Niña fuerte (ENFEN 2012), muestra anomalías negativas de temperatura en el pacífico Este (región Niño 1+2), entre abril del 2007 hasta octubre del 2007, pero a la vez hay una presencia gradual de anomalías negativas de temperatura en el pacífico central (regiones Niño 4, Niño 3.4 y Niño 3) entre octubre del 2007 hasta marzo del 2008 (Figura 45a) el cual es considerado como Niña Fuerte (basado en ONI). Así mismo, se muestra la evolución espacial y temporal de la Niña 2013 (Figura 45b), catalogado por el ICEN como Niña fuerte, iniciando en abril 2013 hasta setiembre 2013, este evento no fue precedido por un evento Niño, como fue la Niña 1998/99 y 2010/11 (Figura 44), reafirmado otra vez que la evolución de ENOS en sus distintas fases es complejo y diferente tanto espacial como temporalmente.

El Niño costero de 1925 presento durante enero a mayo de 1925 la TSM en promedio de 26.5°C en el pacífico oriental (entre 90W-80W de longitud) en la región Niño 1+2 (Figura 46a).

Se muestra anomalías positivas de la TSM en el pacífico oriental (región Niño 1+2), entre enero y mayo de 1925 (Figura 46b), lo presentado en la Figura 46b indica que los máximos valores de la ATSM se presentan en el mes de febrero y abril.

Se observa también que en 1924 hubo anomalías negativas entre mayo y octubre de 1924 (entre 180E-80W de longitud) en todo el pacífico ecuatorial, y posteriormente a setiembre

del 1925 se muestra anomalías positivas (Figura 46b) en las regiones Niño (entre 180E-80W de longitud).

Se entiende de esta exploración de datos que el ENOS en sus distintas fases y evoluciones a lo largo del tiempo, tiene comportamientos distintos y es muy particular en cada evento, lo que lo hace, que el pronóstico es muy complicado debido a la no linealidad y homogeneidad de los datos en el tiempo y espacio.

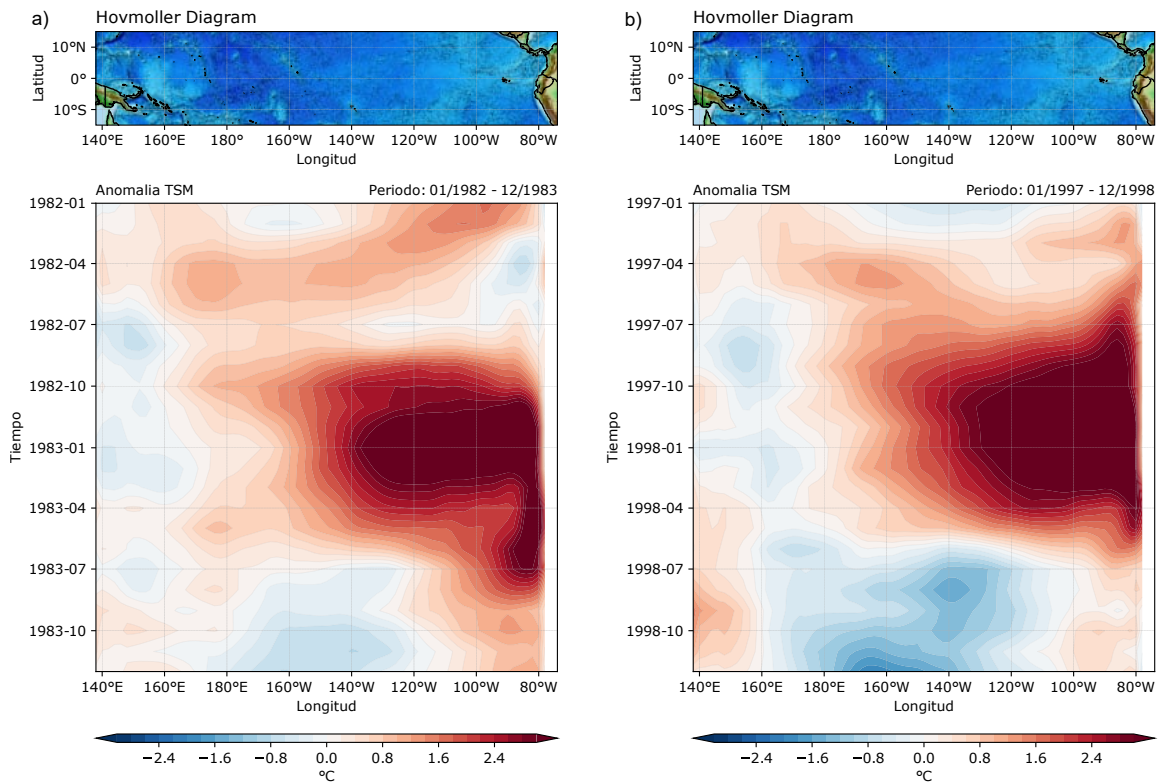


Figura 43: Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 1982/83 y b) 1997/98 para Niños Extraordinarios

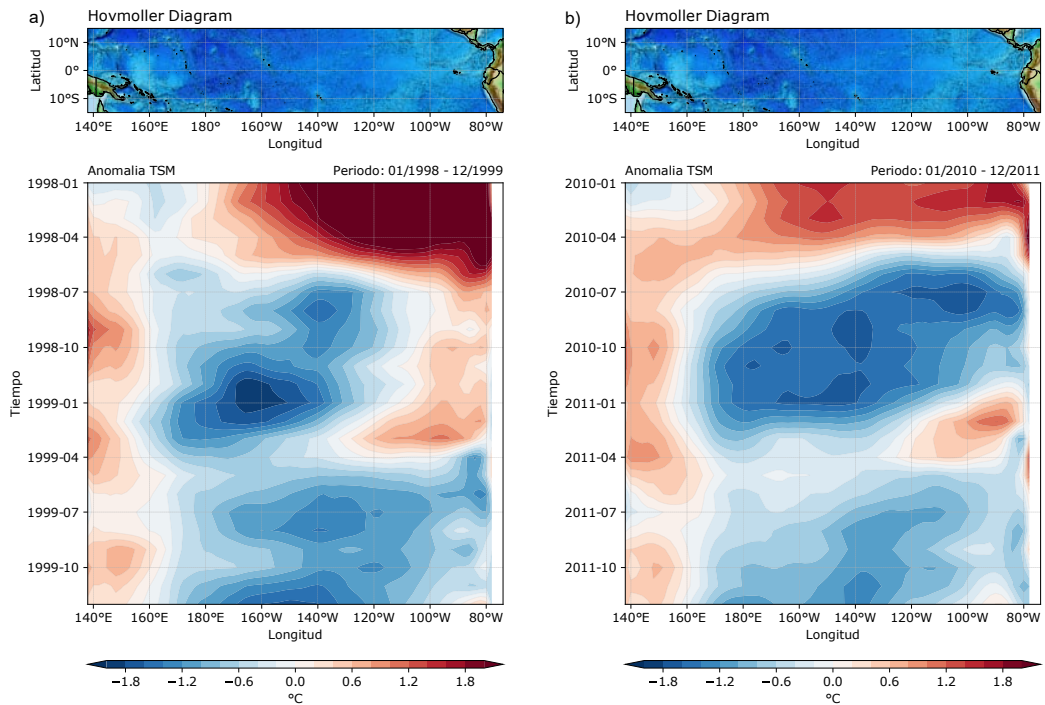


Figura 44: Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 1998/99 y b) 2010/11 para Niña Fuerte en el pacífico central

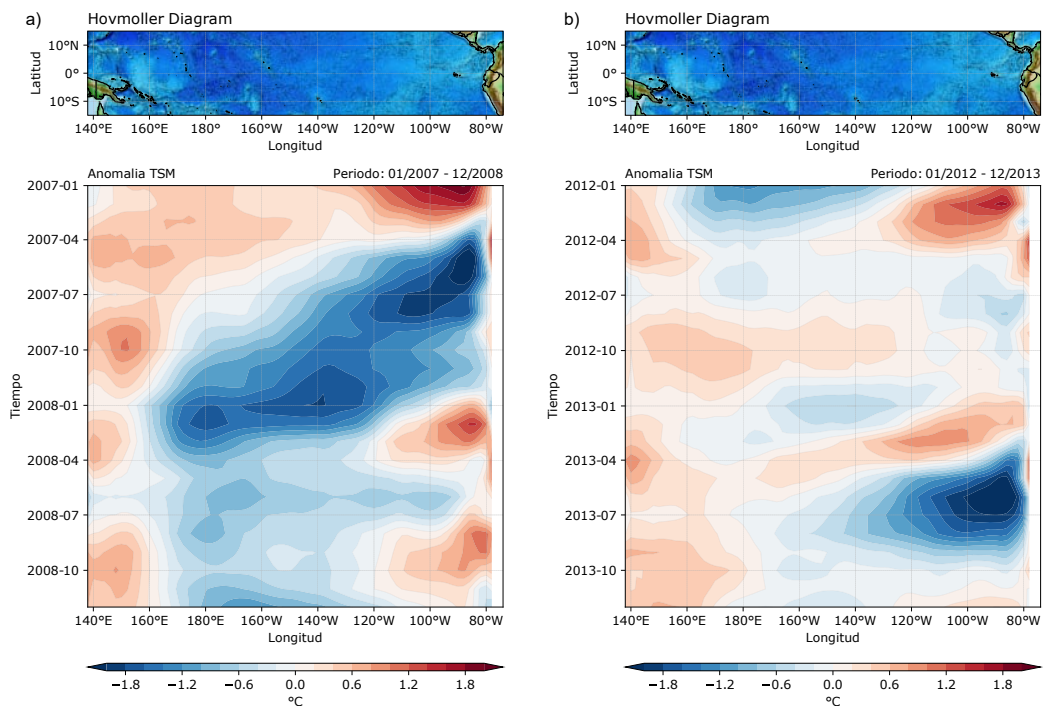


Figura 45: Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre a) 2007/08 y b) 2012/13

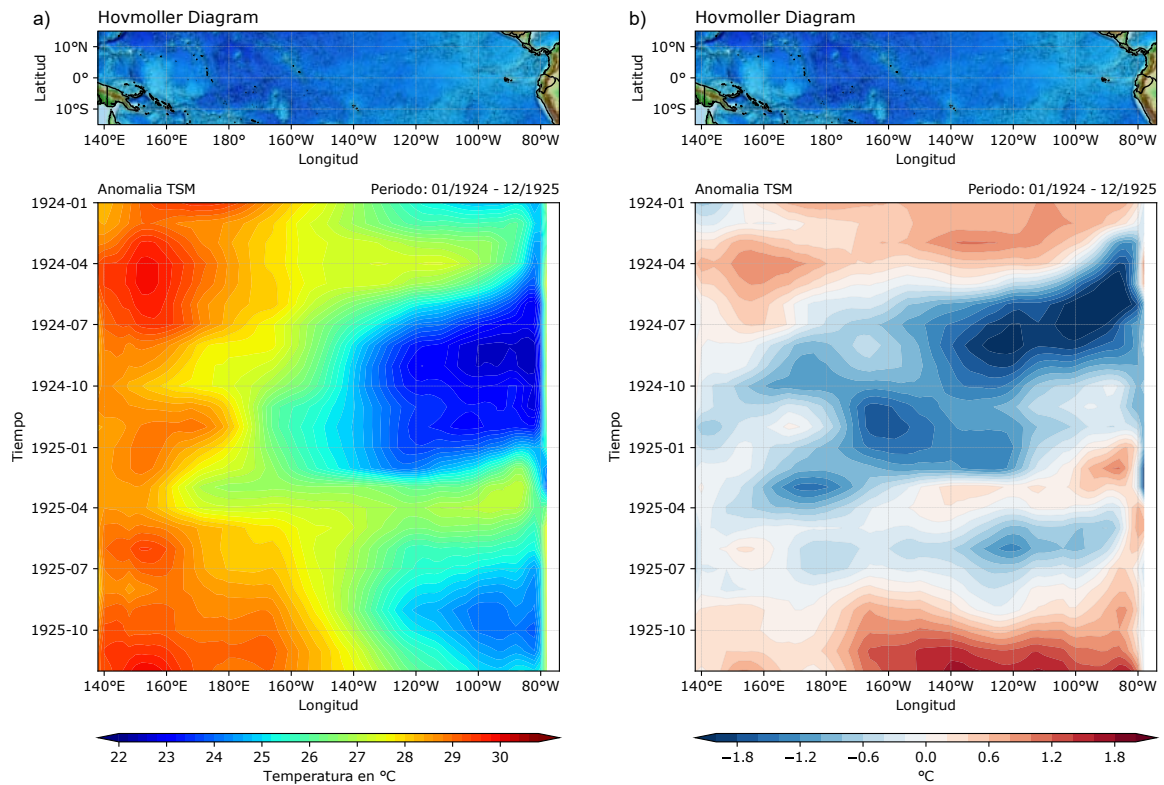


Figura 46: Diagrama de longitud-tiempo (Hovmöller) de anomalía de la TSM en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W, durante enero a diciembre de 1924/25 a) TSM y b) anomalías de la TSM

4.1.3. Exploración de datos espectral temporal de los índices de la ATSM del Niño 3.4 Y Niño 1+2

Se elabora la exploración de datos utilizando herramientas de análisis espectral Wavelet para las series de tiempo de las ATSM del índice Niño 3.4 y Niño 1+2.

Para la serie de tiempo de la ATSM del índice Niño 3.4 (Figura 47a) se registró ciclos de variabilidad estadísticamente significativos en: 2.1, 3 y 3.7 años (Figura 47b y Figura 47c). Dentro de estos ciclos, se destaca el ciclo 3.7 años de periodicidad, el cual tiene una fuerte y significativa señal entre los años 1982-1991 observada a través del análisis Wavelet (95 por ciento de confianza, Figura 47b y Figura 47c).

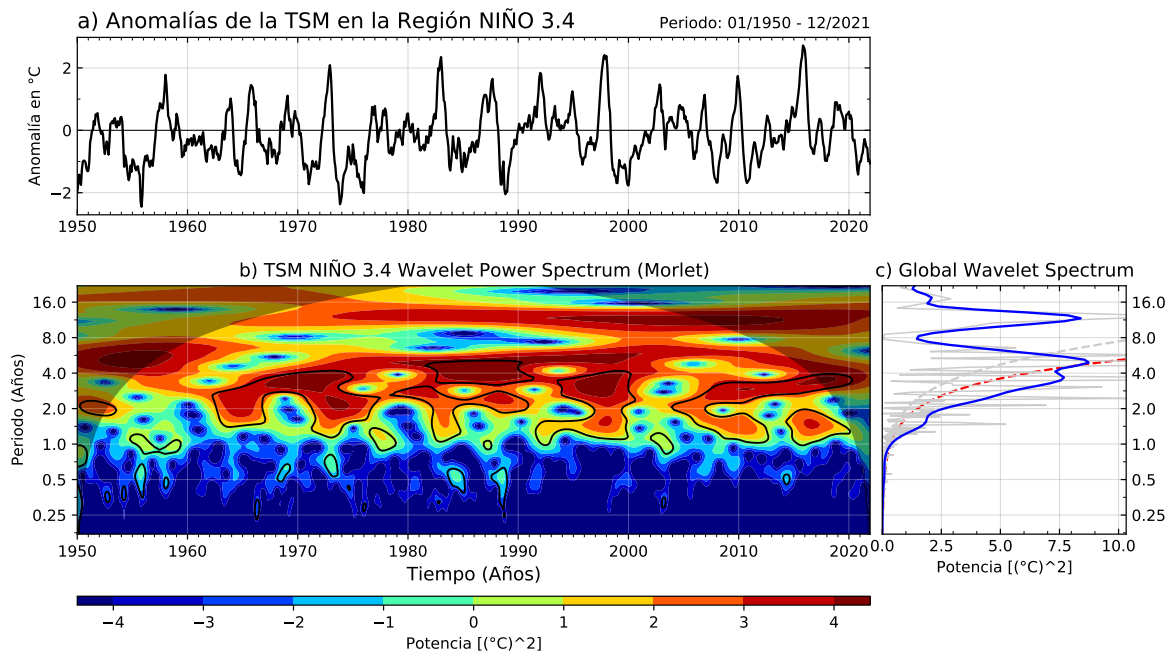


Figura 47: Análisis espectral de potencia del índice climático Niño 3.4 de 1950 al 2021
a) serie de tiempo de la ATSM, b) Análisis Wavelet tipo Morlet de la serie de tiempo de la ATSM, señales de colores rojo intenso se refieren a una mayor potencia espectral los de color azul menor potencia espectral, las áreas enmarcadas en líneas de color negro representan señales espectrales estadísticamente significantes a un 95 por ciento de confianza. El cono de influencia (colores más nítidos) marca el límite donde el análisis Wavelet es confiable y c) Análisis espectral computado para la serie de tiempo de la ATSM, la línea discontinua de color rojo es la significación estadística del 95 por ciento de confianza

Para la serie de tiempo de la ATSM del índice Niño 1+2 (Figura 48a) se registra ciclos de variabilidad estadísticamente significativos en: 2.2 y 3.7 años (Figura 48b y 48c). Dentro de estos ciclos, se destaca el ciclo 3.7 años de periodicidad, el cual tiene una fuerte y significativa señal entre los años de 1967-1988 y de 1996-2000 observada a través del análisis Wavelet (95 por ciento de confianza, Figura 48b).

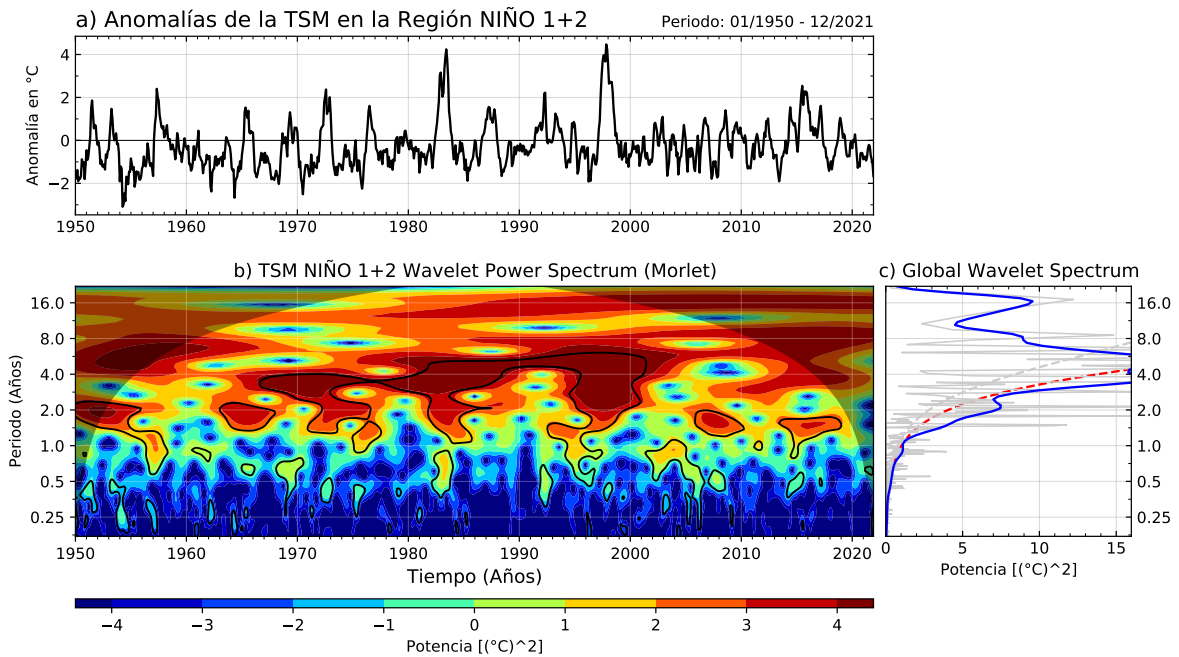


Figura 48: Análisis espectral de potencia del índice climático Niño 1+2 de 1950 al 2021
a) serie de tiempo de la ATSM, b) Análisis Wavelet tipo Morlet de la serie de tiempo de la ATSM, señales de colores rojo intenso se refieren a una mayor potencia espectral los de color azul menor potencia espectral, las áreas enmarcadas en líneas de color negro representan señales espectrales estadísticamente significantes a un 95 por ciento de confianza. El cono de influencia (colores más nítidos) marca el límite donde el análisis Wavelet es confiable y c) Análisis espectral computado para la serie de tiempo de la ATSM, la línea discontinua de color rojo es la significación estadística del 95 por ciento de confianza

Se observa que los índices del Niño 3.4 y Niño 1+2 exhiben relaciones a escala temporal interanual esto debido a una fuerte modulación producida por la interacción del océano y la atmósfera, el cual estaría ocurriendo en ciclos de 3.7 años en promedio.

4.2. MODELO DE RED NEURONAL PROFUNDA, QUE INTEGRA LA MEMORIA CONVOLUCIONAL A CORTO Y LARGO PLAZO (CONVLSTM)

Con la información, la exploración y análisis de datos observado en la sección anterior, se elabora el modelo ConvLSTM, acondicionado con todos esos eventos analizados de ENOS.

En esta sección se describe la arquitectura y algoritmo realizado de la red neuronal profunda de memoria convolucional a corto y largo plazo, planteado para pronosticar el ENOS. Se diseña la arquitectura del modelo utilizando el framework Keras (Chollet 2015). Se entrenó

con el optimizador de Adam (Kingma y Ba 2014) y la pérdida de regresión mediante el Error Cuadrático Medio (MSE) para minimizar el RMSE, MAE, RMSPE y MAPE entre lo pronosticado y el valor verdadero, se iteraron 5 000 épocas usando tasas de aprendizaje decrecientes. El modelo ConvLSTM tiene una matriz de entrada con dimensiones de 12 x 75 (zona del pacífico ecuatorial, latitud 10N-10S y longitud 140E-80W) con todos los datos de la TSM mes a mes desde 1854 hasta 2014 preservando la información espacial. La red consta de cuatro capas ConvLSTM (Tabla 7) con 32 filtros, un tamaño de kernel de 3 x 3, seguida de una capa Conv3D con 16 filtros, un tamaño de kernel de 1 x 1 y una función de activación ReLU completamente conectada que aprende cómo hacer un pronóstico del próximo mes o meses (Figura 36). Esta última capa Conv3D es una capa Deconvolucional (Zeiler *et al.* 2010) que cumple la función de recuperar la extensión espacial de la entrada y para mapear las características de los datos espaciales a un solo valor de TSM en cada celda de la cuadrícula (grilla). Este mapa de TSM es el pronóstico de salida para el próximo mes o meses.

El modelo ConvLSTM consta de 65 361 parámetros para entrenar (Tabla 7), todos estos datos se procesaron en una CPU Intel Core i7-9700 @ 3.00 GHz, con tarjeta de video externa NVIDIA GeForce GTX 1660 SUPER, el entrenamiento llevo 2.5 horas aproximadamente.

Las Figuras 49a y 49b observan el desempeño del modelo (Pérdida del modelo) durante las dos etapas (entrenamiento y validación), se muestra que el desempeño es descendente hasta la época 5000, época que corresponde a finalizar el entrenamiento del modelo. También se observa haciendo un acercamiento (Figura 49c y 49d) que la validación tiene pérdidas inferiores al entrenamiento desde 220 hasta 5000 épocas.

Tabla 7: Número de capas, dimensiones y número de parámetros del modelo

Layer (type)	Output Shape	Param #
conv_lstm2d_1 (ConvLSTM2D)	(None, None, 12, 75, 16)	9856
conv_lstm2d_2 (ConvLSTM2D)	(None, None, 12, 75, 16)	18496
conv_lstm2d_3 (ConvLSTM2D)	(None, None, 12, 75, 16)	18496
conv_lstm2d_4 (ConvLSTM2D)	(None, None, 12, 75, 16)	18496
conv3d_1 (Conv3D)	(None, None, 12, 75, 1)	17
Total params: 65361		
Trainable params: 65361		
Non-trainable params: 0		

Código Fuente 1: ConvLSTM.py

```
1 from keras.models import Sequential
2 from keras.layers.convolutional import Conv3D
3 from keras.layers.convolutional_recurrent import ConvLSTM2D
4 from keras.layers import Dropout
5 from keras.models import load_model
6
7 height, width = 12, 75
8
9 def model():
10     seq = Sequential()
11     seq.add(ConvLSTM2D(filters=16, kernel_size=(3, 3),
12                       input_shape=(None, height, width, 1),
13                       padding='same', return_sequences=True))
14     seq.add(ConvLSTM2D(filters=16, kernel_size=(3, 3),
15                       padding='same', return_sequences=True))
16     seq.add(ConvLSTM2D(filters=16, kernel_size=(3, 3),
17                       padding='same', return_sequences=True))
18     seq.add(ConvLSTM2D(filters=16, kernel_size=(3, 3),
19                       padding='same', return_sequences=True))
20     seq.add(Conv3D(filters=1, kernel_size=(1, 1, 1),
21                  activation='relu', padding='same',
22                  data_format='channels_last'))
23     return seq
24
```

El entrenamiento y validación se lleva a cabo hasta obtener la pérdida de regresión adecuada, se muestra en la Tabla 7 la pérdida de regresión del modelo en etapa de entrenamiento y validación resultado un MSE en calibración de 2.893×10^{-4} y validación de 2.753×10^{-4} , indicando significancia del modelo ConvLSTM.

Según Sanders (1997), Hyndman (2006) y Makridakis *et al.* (2008), un valor de MSE próximo o cercano a cero significa que los valores pronosticados están cerca o próximos a los valores reales (observados). Por lo cual se concluye que los valores de MSE del modelo ConvLSTM cumplen esta condición.

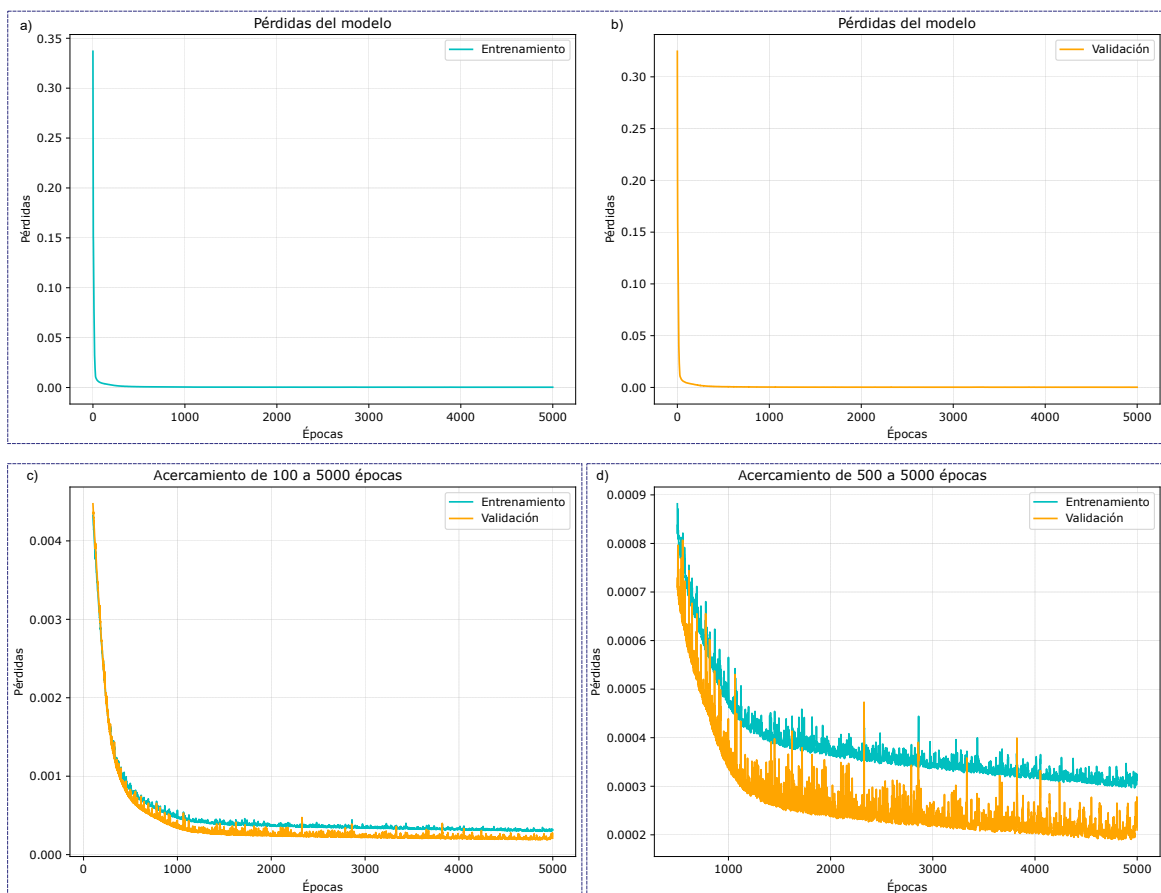


Figura 49: Curva de desempeño del modelo ConvLSTM en 5000 épocas a) Entrenamiento (calibración), b) Validación c) Acercamiento de entrenamiento - validación de 100 a 5000 épocas d) Acercamiento de entrenamiento- validación de 500 a 5000 épocas

Tabla 8: Estadísticos de pérdida de regresión del modelo de pronóstico con respecto a los valores verdaderos de las ATSM promediados en todas las celdas de la cuadrícula

Modelo	Pérdida de regresión	Calibración (Entrenamiento)	Validación
ConvLSTM	MSE	2.893×10^{-4}	2.753×10^{-4}

4.3. MODELO DE RED NEURONAL PROFUNDA PARA PRONÓSTICOS EL NIÑO EXTRAORDINARIO 1982/83 Y 1997/98

En esta sección se aborda el pronóstico mediante data calibrada y validada del Modelo ConvLSTM, para eventos Niños Extraordinarios, de los años 1982/83 y 1997/98, ya que la base de datos de calibración es el periodo de enero de 1854 hasta diciembre 1996 estando en esta etapa el evento Niño 1982/83 y la validación en el periodo de enero de 1997 hasta diciembre 2013 estando en esta etapa el evento Niño 1997/98.

Se aborda la zona latitud 10°S – 10°N , longitud 140°E – 80°W , ya que son las zonas donde se ubican las regiones Niño (Niño 1+2, Niño 3, Niño 4 y Niño 3.4) y es el interés de esta investigación. Para ello se utilizaron datos de TSM y anomalías de TSM de la zona mencionada.

El pronóstico se llevó a cabo con seis meses de anticipación del evento, por ejemplo, para pronosticar el evento Niño 1982/83 (Figura 50) se usó datos hasta setiembre de 1982, y se muestra pronósticos de octubre de 1982 hasta marzo 1983 (meses de mayor evolución del Niño extraordinario), habiendo un pronóstico de seis meses de anticipación.

De hecho, se puede ver con una inspección visual, un muy buen pronóstico del año 1982/83 (Figura 50) y 1997/98 (Figura 51). A fin de poder realizar una comparación más exhaustiva, se calculó métricas estadísticas, que permitieron conocer la estructura del error mes a mes de cada uno de los eventos pronosticados.

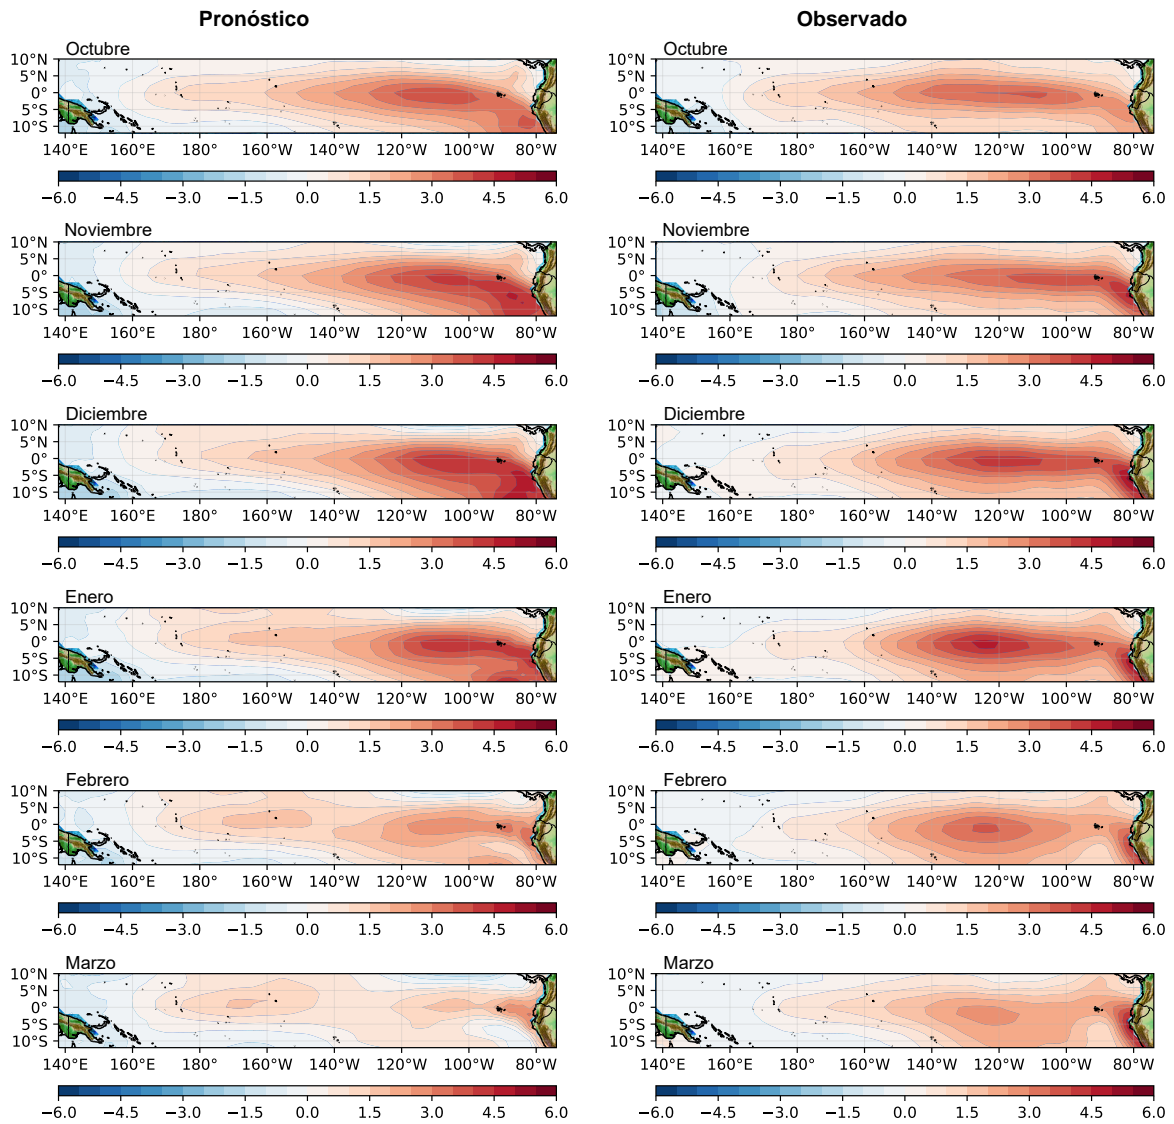


Figura 50: Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de Octubre a marzo de 1982/83 en etapa de calibración del evento Niño Extraordinario, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

Se calculó métricas estadísticas en función de cada una de las celdas de la cuadrícula en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) para el año 1982/83 y 1997/98.

Tal como se observa en la Tabla 9 para el Niño 1982/83, las métricas estadísticas entre las anomalías de la TSM pronosticados y observados mes a mes del Niño 1982/83 realizadas por el modelo ConvLSTM en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W), muestran mucha variación, con respecto al RMSPE, para octubre 1982 y marzo 1983 la métrica estadística muestra una EXCELENTE precisión del pronostico con RMSPE <10 por ciento, según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para noviembre de

1982, enero y febrero de 1983 es BUENA precisión del pronóstico (10 por ciento $<RMSPE \leq 20$ por ciento), y para diciembre es REGULAR precisión del pronóstico (20 por ciento $<RMSPE \leq 30$ por ciento).

En el caso de la métrica estadística de MAPE de la Tabla 9 se muestran que en todos los meses los valores se aproximan a cero con MAPE <10 por ciento, el cual es EXCELENTE precisión del pronóstico, según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Para las regiones Niño 3.4 y Niño 1+2 para el año 1982/83, se muestran las métricas estadísticas en las Tablas 10 y 11 respectivamente, dando como resultando mes a mes buena significancia estadística ya que los valores se aproximan a cero y los estadísticos porcentuales también se aproximan a cero, según las Tablas 4 y 5 (Lewis 1982; Jamieson *et al.* 1991; Chen *et al.* 2003; Li *et al.* 2013) para RMSPE y MAPE respectivamente. Para el caso de la región Niño 3.4 se obtiene valores promedio de RMSPE de 0.71 por ciento (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico) y MAPE de 0.41 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), para la región Niño 1+2 se obtiene RSMPE de 0.47 por ciento (RSMPE <10 por ciento, es EXCELENTE precisión del pronóstico y MAPE de 0.36 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico).

En general, se concluye que para el Niño 1982/83 en las regiones Niño 3.4 y Niño 1+2, se observa que en todos los meses las anomalías de la TSM pronosticadas y observadas tienen buena significancia estadística.

Tabla 9: Métricas estadísticas del Niño Extraordinario 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) de octubre a marzo del 1982/83

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1982/83	MSE	0.199	0.319	0.562	0.688	0.609	0.832	0.535
	RMSE	0.446	0.565	0.750	0.829	0.781	0.912	0.714
	<i>RMSPE</i> ¹	<i>2.30</i>	<i>15.02</i>	<i>24.69</i>	<i>16.51</i>	<i>15.03</i>	<i>6.25</i>	<i>13.30</i>
	MAE	0.343	0.417	0.593	0.663	0.626	0.695	0.556
	<i>MAPE</i> ¹	<i>0.76</i>	<i>2.92</i>	<i>8.48</i>	<i>7.14</i>	<i>4.48</i>	<i>1.86</i>	<i>4.27</i>

Tabla 10: Métricas estadísticas de Niño Extraordinario 1982/83 de la región Niño 3.4 (5N-5S, 170W-120W) de octubre a marzo del 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1982/83	MSE	0.172	0.123	0.394	0.939	0.867	0.982	0.580
	RMSE	0.414	0.351	0.628	0.969	0.931	0.991	0.714
	<i>RMSPE</i> ¹	<i>0.23</i>	<i>0.22</i>	<i>0.39</i>	<i>1.77</i>	<i>1.06</i>	<i>0.59</i>	<i>0.71</i>
	MAE	0.376	0.313	0.558	0.841	0.814	0.805	0.618
	<i>MAPE</i> ¹	<i>0.20</i>	<i>0.18</i>	<i>0.29</i>	<i>0.67</i>	<i>0.57</i>	<i>0.52</i>	<i>0.41</i>

Tabla 11: Métricas estadísticas de Niño Extraordinario 1982/83 de la región Niño 1+2 (0-10S, 90W-80W) de octubre a marzo del 1982/83, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1982/83	MSE	0.769	1.475	1.271	0.804	0.550	2.831	1.283
	RMSE	0.877	1.215	1.127	0.897	0.742	1.682	1.090
	<i>RMSPE</i> ¹	<i>0.43</i>	<i>0.51</i>	<i>0.45</i>	<i>0.41</i>	<i>0.27</i>	<i>0.73</i>	<i>0.47</i>
	MAE	0.751	1.017	0.914	0.711	0.564	1.412	0.895
	<i>MAPE</i> ¹	<i>0.36</i>	<i>0.37</i>	<i>0.32</i>	<i>0.28</i>	<i>0.22</i>	<i>0.59</i>	<i>0.36</i>

¹Porcentajes

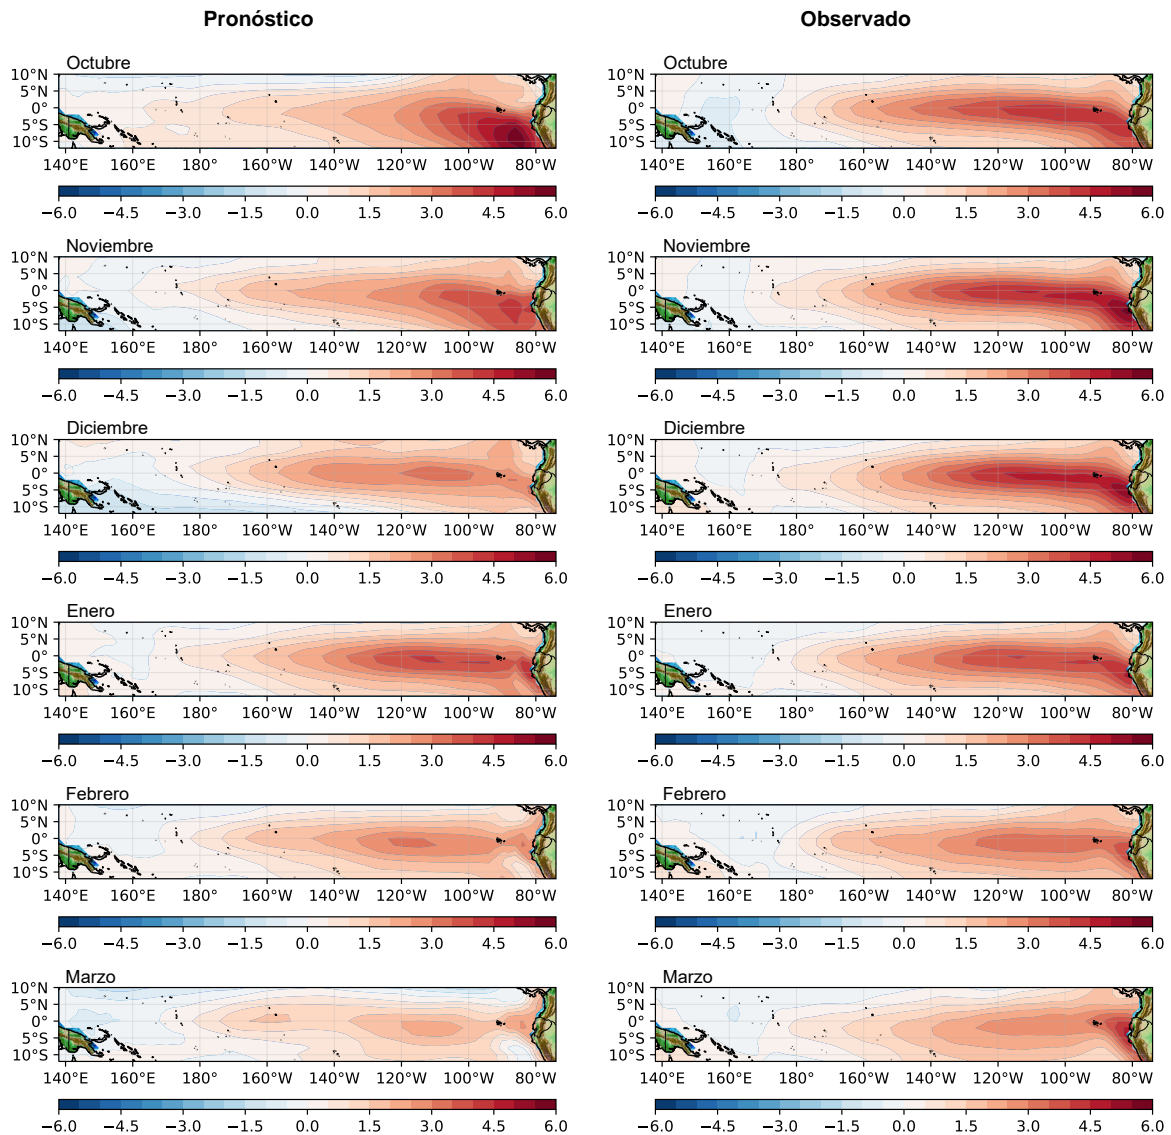


Figura 51: Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de Octubre a marzo de 1997/98 en etapa de calibración del evento Niño Extraordinario, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

La Tabla 12 muestra las métricas estadísticas entre las anomalías de la TSM pronosticados y observados mes a mes del Niño 1997/98 realizadas por el modelo ConvLSTM en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W), con respecto al RMSPE, para noviembre 1997 y febrero 1998 muestran una EXCELENTE precisión del pronóstico (RMSPE <10 por ciento) según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras que para marzo es BUENA precisión del pronóstico (10 por ciento <RMSPE <= 20 por ciento), para octubre-diciembre de 1997 y enero 1998 es REGULAR precisión del pronóstico (20 por ciento <RMSPE <= 30 por ciento).

Tabla 12: Métricas estadísticas del Niño Extraordinario 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W) de octubre a marzo del 1997/98

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1997/98	MSE	0.651	0.297	0.772	0.057	0.163	0.578	0.420
	RMSE	0.807	0.545	0.879	0.239	0.404	0.760	0.606
	<i>RMSPE</i> ²	<i>23.92</i>	<i>1.43</i>	<i>22.62</i>	<i>22.77</i>	<i>7.67</i>	<i>12.60</i>	<i>15.17</i>
	MAE	0.648	0.386	0.686	0.179	0.288	0.565	0.459
	<i>MAPE</i> ²	<i>3.23</i>	<i>0.56</i>	<i>3.88</i>	<i>2.79</i>	<i>1.03</i>	<i>2.54</i>	<i>2.34</i>

Tabla 13: Métricas estadísticas de Niño Extraordinario 1997/98 de la región Niño 3.4 (5N-5S, 170W-120W) de octubre a marzo del 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1997/98	MSE	0.863	0.609	0.343	0.047	0.084	0.357	0.384
	RMSE	0.929	0.780	0.586	0.217	0.289	0.598	0.567
	<i>RMSPE</i> ²	<i>0.40</i>	<i>0.27</i>	<i>0.37</i>	<i>0.17</i>	<i>0.17</i>	<i>2.60</i>	<i>0.66</i>
	MAE	0.832	0.622	0.480	0.187	0.218	0.518	0.476
	<i>MAPE</i> ²	<i>0.37</i>	<i>0.24</i>	<i>0.28</i>	<i>0.12</i>	<i>0.12</i>	<i>0.86</i>	<i>0.33</i>

Tabla 14: Métricas estadísticas de Niño Extraordinario 1997/98 de la región Niño 1+2 (0-10S, 90W-80W) de octubre a marzo del 1997/98, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Oct	Mes 2 Nov	Mes 3 Dic	Mes 4 Ene	Mes 5 Feb	Mes 6 Mar	Prom
1997/98	MSE	1.390	0.981	3.623	0.286	1.039	3.612	1.822
	RMSE	1.179	0.991	1.903	0.535	1.019	1.901	1.255
	<i>RMSPE</i> ²	<i>0.33</i>	<i>0.21</i>	<i>0.44</i>	<i>0.14</i>	<i>0.37</i>	<i>0.68</i>	<i>0.36</i>
	MAE	0.922	0.832	1.824	0.415	0.924	1.786	1.117
	<i>MAPE</i> ²	<i>0.25</i>	<i>0.18</i>	<i>0.43</i>	<i>0.11</i>	<i>0.32</i>	<i>0.63</i>	<i>0.32</i>

²Porcentajes

En las regiones Niño 3.4 y Niño 1+2 para el año 1997/98, se muestran las métricas estadísticas en las Tablas 13 y 14 respectivamente, dando como resultando mes a mes buena significancia estadística ya que los valores se aproximan a cero y los estadísticos porcentuales también se aproximan a cero, según las Tablas 4 y 5 (Lewis 1982; Jamieson *et al.* 1991; Chen *et al.* 2003; Li *et al.* 2013) para RMSPE y MAPE respectivamente. Para el caso de la región Niño 3.4 se obtiene valores promedio de RMSPE de 0.66 por ciento (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico y MAPE de 0.33 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), para la región Niño 1+2 se obtiene RMSPE de 0.36 por ciento (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico) y MAPE de 0.32 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico).

En general, se concluye que para el Niño 1997/98 en las regiones Niño 3.4 y Niño 1+2, se observa que en todos los meses las anomalías de la TSM pronosticadas y observadas tienen buena significancia estadística.

4.4. PRONÓSTICO DE ANOMALÍAS DE LA TSM DE LAS REGIONES NIÑO 3.4 Y NIÑO 1+2, MEDIANTE LA RED NEURONAL PROFUNDA

En esta sección, se muestra los resultados de pronósticos de eventos ENOS del año 2015/16 (Niño extraordinario), año 2016/17 (Niño Costero) y 2022 (La Niña), con datos de Prueba (test), se mencionó anteriormente que los datos de prueba son desde enero 2015 a junio 2022, los cuales no fueron utilizados en entrenamiento (calibración) tampoco en validación, por lo cual es data no conocida por el modelo ConvLSTM.

4.4.1. Pronóstico de las ATSM y TSM del niño extraordinario 2015/16

El Niño extraordinario 2015/16 fue uno de los eventos de El Niño más fuertes observados desde el año de 1950, comparándolos con los eventos Niño 1982/83 y 1997/98, así mismo tuvo lugar casi dos décadas después del evento Niño anterior de 1997/98. L'Heureux *et al.* (2017) publicó en su artículo científico que este evento Niño 2015/16 difirió en formas únicas e importantes con los Niños extraordinarios antes mencionados, comenta también, que a diferencia de El Niño 1997/98, se produjeron anomalías de la TSM notablemente superiores a la media en el Pacífico ecuatorial occidental y central, pero fueron más leves cerca de la costa de América del Sur. Es por tal motivo analizar y tener en cuenta toda esa

información para el pronóstico del Niño 2015/16 con el modelo ConvLSTM.

Recordar que, en esta sección, se muestra pronósticos en dos etapas del Niño 2015/16, con la finalidad de ver la calidad del pronóstico en diferentes meses, vale recordar también que puede hacerse el pronóstico para cualquier mes de inicio que se desea.

Primera etapa, de julio a diciembre del 2015, etapa de mayor evolución del Niño 2015/16

En la Figura 52, se muestra el pronóstico de la TSM de los datos pronosticados y observados, durante el periodo de julio a diciembre del 2015, se observa que la TSM pronosticada y observada tiene un comportamiento similar de evolución de la temperatura, para tener un mayor entendimiento de la evolución del Niño 2015/16, se muestra las ATSM en la Figura 53, valga recordar que las anomalías se calculan con respecto a la climatología de 1981-2010.

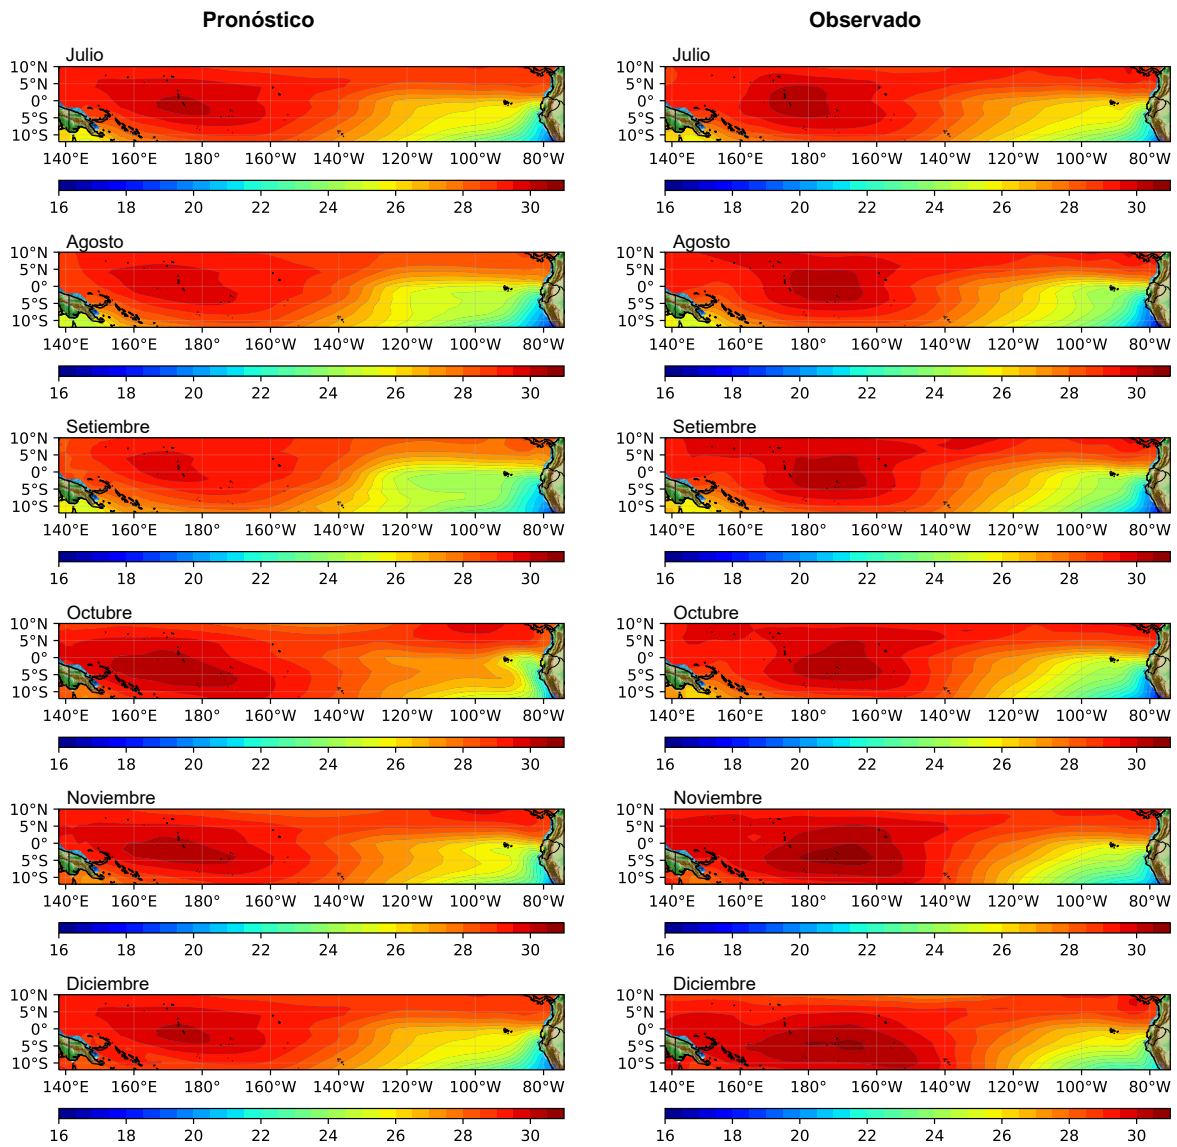


Figura 52: TSM pronosticado (izquierda) y observado (derecha) de a julio a diciembre 2015 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

Respecto a las ATSM de data pronosticada y observada (Figura 53), para el pronóstico del Niño 2015/16, se llevó a cabo con 6 meses de anticipación del evento, en este ejemplo, se alimenta al modelo con información de enero a junio del 2015, se muestra pronósticos de julio a diciembre de 2015 (Figura 53, meses de inicio de la evolución del Niño extraordinario 2015/16), habiendo un pronóstico de 6 meses de anticipación, para su comparación y compresión entre lo pronosticado y observado utilizamos las métricas estadísticas mencionadas anteriormente el cual se muestran los resultados en la Tabla 15.

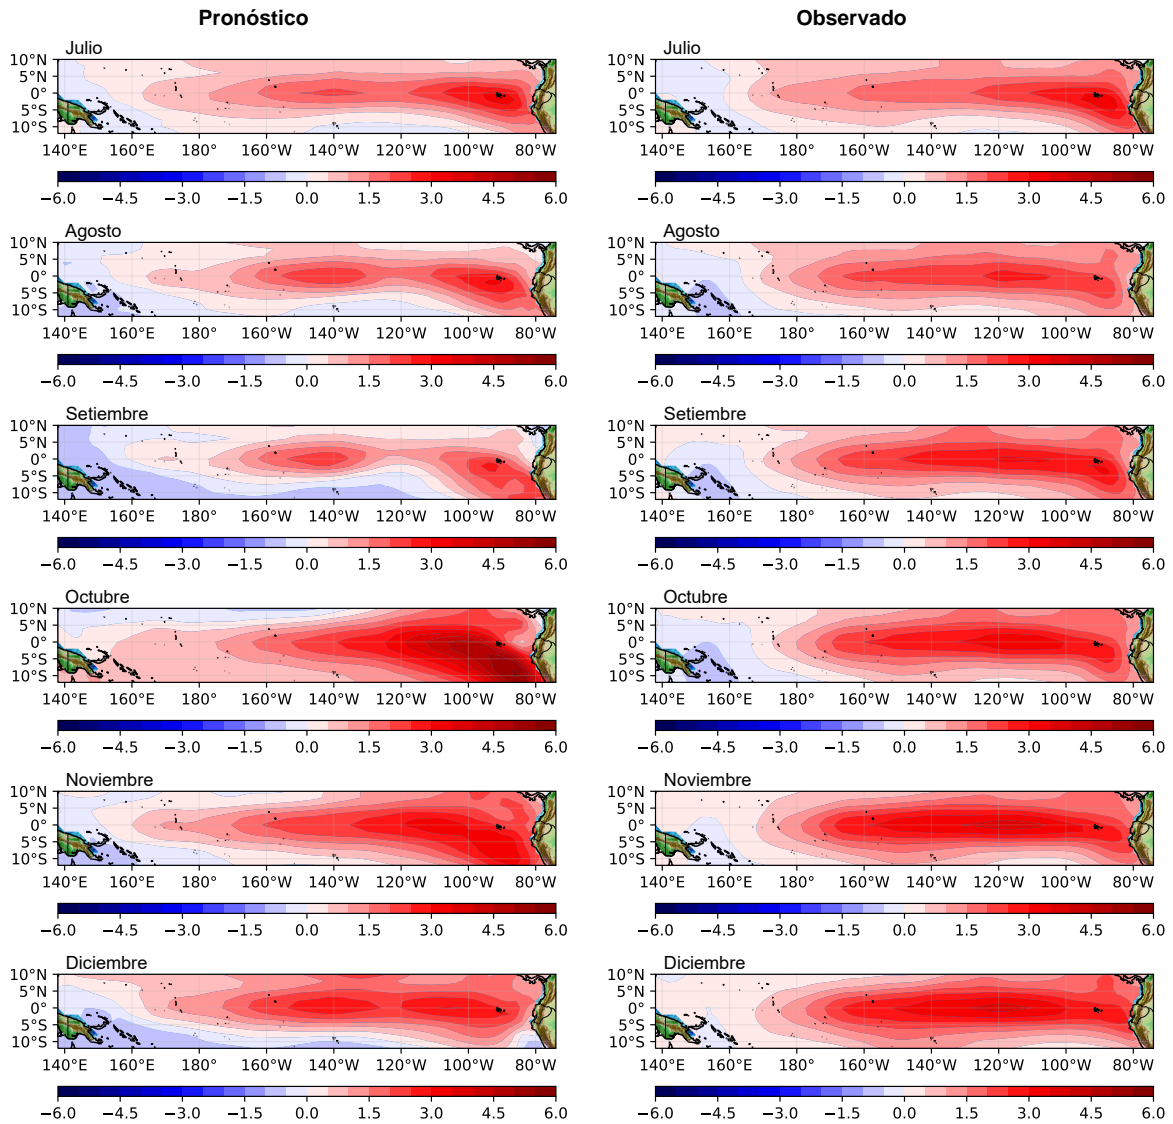


Figura 53: TSM pronosticado (izquierda) y observado (derecha) de a julio a diciembre 2015 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

Tal como se observa en la Tabla 15 para el Niño 2015/16, las métricas estadísticas entre las anomalías de la TSM pronosticados y observados mes a mes realizadas por el modelo ConvLSTM en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W), muestran mucha variación, con respecto al RMSPE, para julio y noviembre de 2015 la métrica estadística porcentual muestra un EXCELENTE pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para agosto y setiembre del 2015 es BUENA precisión del pronóstico (10 por ciento <RMSPE <= 20 por ciento), para octubre 2015 es REGULAR precisión del pronóstico (20 por ciento <RMSPE <= 30 por ciento), y para diciembre un RMSPE >30 por ciento el cual es MALA precisión del pronóstico.

En el caso de la métrica estadística de MAPE la Tabla 15 muestra que en todos los meses hay buena significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento), el cual es EXCELENTE precisión del pronóstico, según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Una vez obtenido los pronósticos de julio a diciembre del 2015 de manera espacial y temporal (Figuras 52 y 53), se calcula las métricas estadísticas solo de las regiones de interés (región Niño 3.4 y Niño 1+2) de la data pronosticada grillada y observada grillada (Tablas 16 y 17), estas métricas estadísticas se estiman para cada celda de la cuadrícula individualmente.

Se muestran las métricas estadísticas en las Tablas 16 y 17 respectivamente, dando como resultando mes a mes buena significancia estadística ya que los valores se aproximan a cero y los estadísticos porcentuales también se aproximan a cero, según Tablas 4 y 5 (Lewis 1982; Jamieson *et al.* 1991; Chen *et al.* 2003; Li *et al.* 2013) para RMSPE y MAPE respectivamente, para el caso de la región Niño 3.4 (Tabla 16) se obtienen valores promedio de RMSPE de 0.35 por ciento (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico) y MAPE de 0.30 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), para la región Niño 1+2 (Tabla 17) se obtiene RSMPE de 0.52 por ciento (RSMPE <10 por ciento, es EXCELENTE precisión del pronóstico) y MAPE de 0.40 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico).

En general, para el pronóstico de julio a diciembre del 2015 en las regiones Niño 3.4 y Niño 1+2, se observa que en todos los meses las anomalías de la TSM pronosticadas y observadas tienen buena significancia estadística.

Tabla 15: Métricas estadísticas de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)

NIÑO	Métricas Estadísticas	Mes 1 Jul	Mes 2 Ago	Mes 3 Sep	Mes 4 Oct	Mes 5 Nov	Mes 6 Dic	Prom
2015/16	MSE	0.047	0.240	0.795	1.056	0.390	0.509	0.506
	RMSE	0.217	0.490	0.892	1.028	0.624	0.713	0.661
	<i>RMSPE</i> ³	<i>3.47</i>	<i>12.58</i>	<i>13.70</i>	<i>24.29</i>	<i>3.26</i>	<i>33.25</i>	<i>15.09</i>
	MAE	0.172	0.403	0.761	0.764	0.496	0.558	0.526
	<i>MAPE</i> ³	<i>0.77</i>	<i>1.77</i>	<i>2.89</i>	<i>3.40</i>	<i>1.22</i>	<i>3.93</i>	<i>2.33</i>

Tabla 16: Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 3.4 (5N-5S, 170W-120W) de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Jul	Mes 2 Ago	Mes 3 Sep	Mes 4 Oct	Mes 5 Nov	Mes 6 Dic	Prom
2015/16	MSE	0.027	0.312	1.199	0.366	0.578	0.474	0.493
	RMSE	0.166	0.559	1.095	0.605	0.760	0.689	0.646
	<i>RMSPE</i> ³	<i>0.15</i>	<i>0.38</i>	<i>0.62</i>	<i>0.35</i>	<i>0.33</i>	<i>0.30</i>	<i>0.35</i>
	MAE	0.143	0.482	0.995	0.526	0.730	0.582	0.576
	<i>MAPE</i> ³	<i>0.12</i>	<i>0.31</i>	<i>0.55</i>	<i>0.28</i>	<i>0.31</i>	<i>0.24</i>	<i>0.30</i>

Tabla 17: Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 1+2 (0-10S, 90W-80W) de julio a diciembre del 2015, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Jul	Mes 2 Ago	Mes 3 Sep	Mes 4 Oct	Mes 5 Nov	Mes 6 Dic	Prom
2015/16	MSE	0.192	0.151	0.379	4.632	0.707	1.161	1.204
	RMSE	0.438	0.388	0.616	2.152	0.841	1.077	0.919
	<i>RMSPE</i> ³	<i>0.19</i>	<i>0.31</i>	<i>0.33</i>	<i>1.15</i>	<i>0.52</i>	<i>0.61</i>	<i>0.52</i>
	MAE	0.358	0.303	0.539	1.771	0.613	0.887	0.745
	<i>MAPE</i> ³	<i>0.16</i>	<i>0.22</i>	<i>0.27</i>	<i>0.93</i>	<i>0.34</i>	<i>0.47</i>	<i>0.40</i>

³Porcentajes

Así también se hizo el análisis de correlación de Pearson para las ATSM pronosticado y observado para los meses más representativos (de mayor correlación significativa), esto fue para los tres primeros meses (julio a setiembre del 2015), ya que ellos son los meses mejor correlacionados, en la Figura 54 se muestra para el área de estudio (latitud 10°S–10°N y longitud 140°E–80°W), se muestra una correlación MUY FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo.

Para la región Niño 3.4, los resultados de correlación de Pearson (Figura 55) de los tres meses de pronóstico, muestran que para los dos primeros meses hay una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), y para el tercer mes una correlación FUERTE ($r > 0.6$, según Tabla 3) indicando significancia del modelo en la región Niño 3.4.

Para la región Niño 1+2, los resultados de correlación de Pearson (Figura 56) muestran que los dos primeros meses tienen una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), y para el tercer mes una correlación FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo en la región Niño 1+2.




Figura 54: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

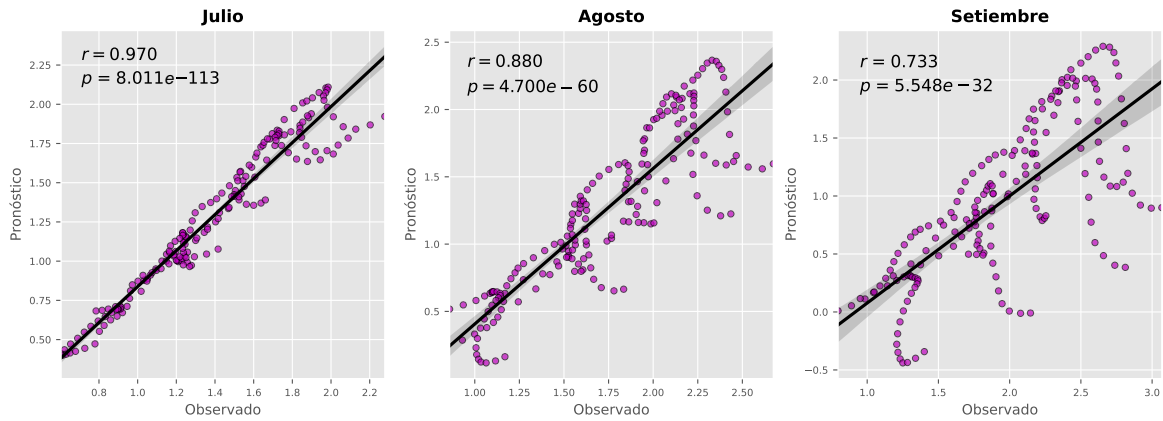


Figura 55: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 3.4 (5N-5S, 170W-120W)




Figura 56: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (julio – setiembre) del 2015 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 1+2 (0-10S, 90W-80W)

Segunda etapa, de enero a junio del 2016, etapa de decaimiento del Niño 2015/16

En la Figura 57, se muestra el pronóstico de la TSM de los datos pronosticados y observados, durante el periodo de enero a junio del 2016, se observa que la TSM pronosticada y observada tiene un comportamiento similar de evolución de la temperatura, para tener un mayor entendimiento de la evolución del Niño 2015/16, se muestra las ATSM en la Figura 58, valga recordar que las anomalías se calculan con respecto a la climatología de 1981-2010.

En la Figura 58 se muestran las ATSM de enero a junio del 2016 pronosticado y observado (meses de mayor evolución del Niño extraordinario 2015/16), mediante el modelo ConvLSTM con 6 meses de anticipación (solo se usó datos de julio a diciembre del 2015) en el océano Pacífico ecuatorial (latitud: 10°S–10°N y longitud: 140°E–80°W), para su comparación y compresión entre lo pronosticado y observado se utilizó las métricas estadísticas mencionadas anteriormente el cual se muestran los resultados en la Tabla 18.

En la Tabla 18 se observan las métricas estadísticas entre las ATSM pronosticados y observados mes a mes realizadas por el modelo ConvLSTM en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W), muestran mucha variación, con respecto al RMSPE, para febrero y marzo del 2016 la métrica estadística porcentual muestra un EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para abril y mayo del 2016 es BUENA precisión del pronóstico (10 por ciento <RMSPE <= 20 por ciento), para enero y junio 2016 es REGULAR precisión del pronóstico (20 por ciento <RMSPE <= 30 por ciento).

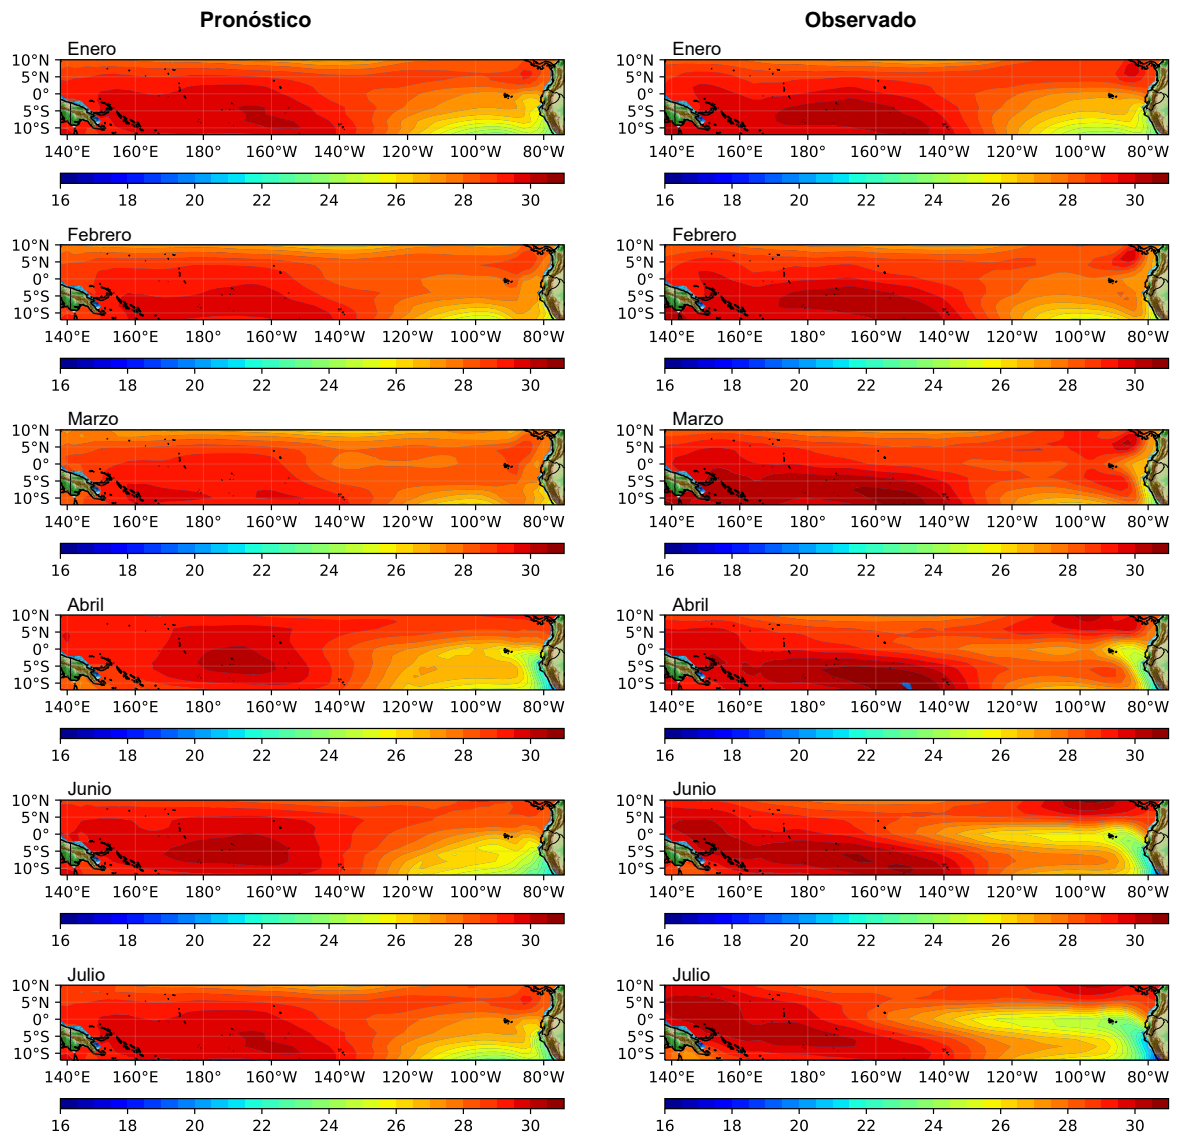


Figura 57: TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2016 en etapa de prueba del evento Niño Extraordinario 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

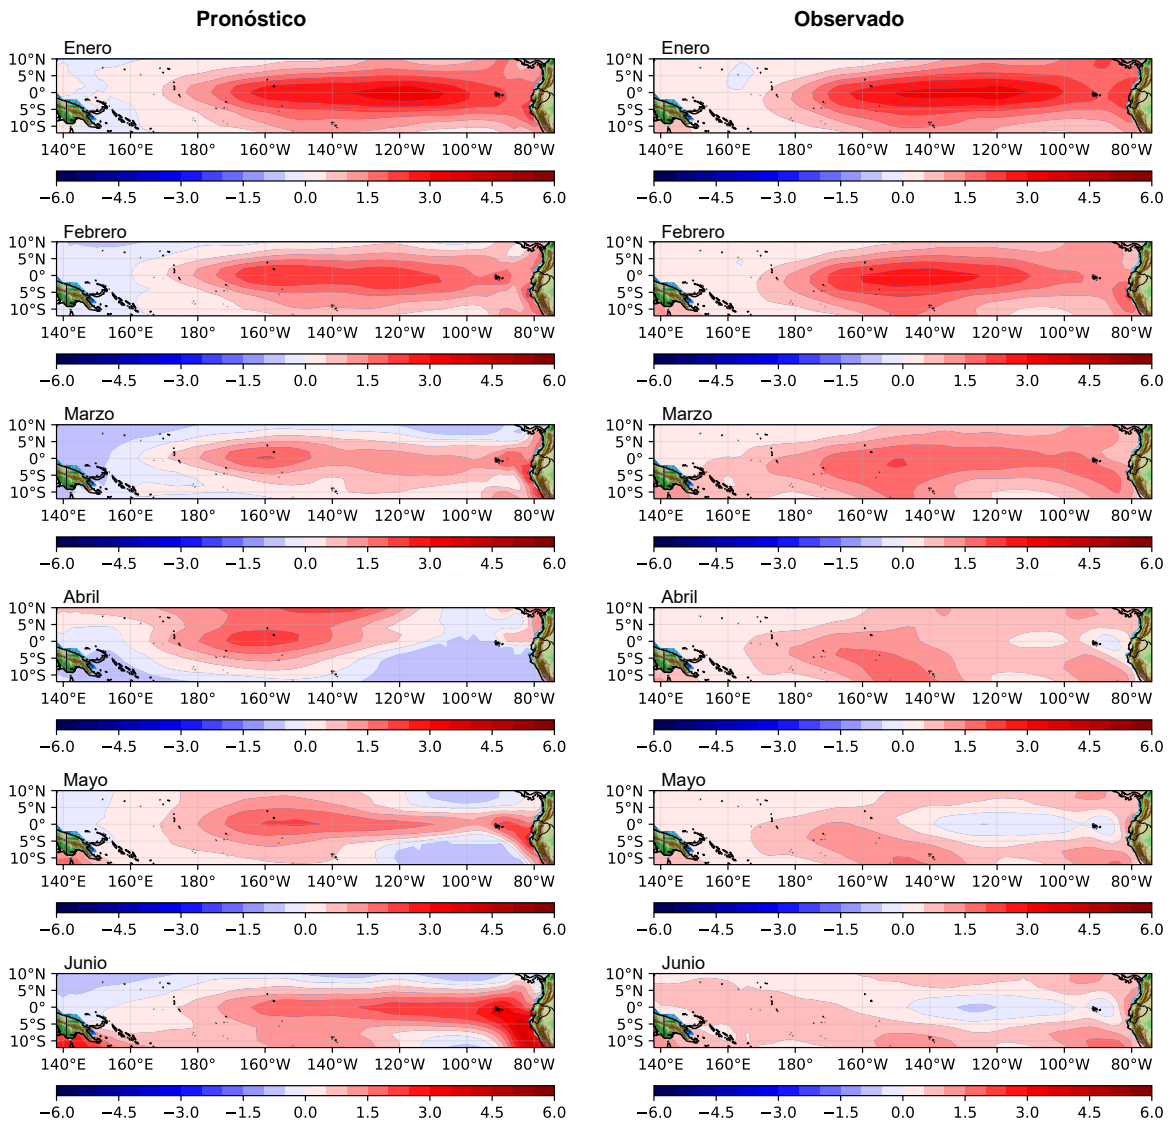


Figura 58: Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2016 en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

Tabla 18: Métricas estadísticas de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)

NIÑO	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2015/16	MSE	0.066	0.176	0.677	0.853	0.768	1.326	0.644
	RMSE	0.256	0.419	0.823	0.923	0.877	1.152	0.742
	<i>RMSPE</i> ⁴	<i>2.66</i>	<i>2.86</i>	<i>1.73</i>	<i>15.56</i>	<i>12.55</i>	<i>26.51</i>	<i>10.31</i>
	MAE	0.196	0.330	0.694	0.786	0.668	0.853	0.588
	<i>MAPE</i> ⁴	<i>0.72</i>	<i>0.95</i>	<i>1.09</i>	<i>2.74</i>	<i>2.85</i>	<i>5.23</i>	<i>2.26</i>

Tabla 19: Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 3.4 (5N-5S, 170W-120W) de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2015/16	MSE	0.031	0.150	0.380	0.525	1.117	1.583	0.631
	RMSE	0.176	0.387	0.616	0.725	1.057	1.258	0.703
	<i>RMSPE</i> ⁴	<i>0.09</i>	<i>0.20</i>	<i>0.40</i>	<i>0.85</i>	<i>13.58</i>	<i>27.89</i>	<i>7.17</i>
	MAE	0.149	0.318	0.533	0.624	0.875	1.008	0.585
	<i>MAPE</i> ⁴	<i>0.07</i>	<i>0.16</i>	<i>0.35</i>	<i>0.68</i>	<i>4.45</i>	<i>9.17</i>	<i>2.48</i>

Tabla 20: Métricas estadísticas de Niño Extraordinario 2015/16 de la región Niño 1+2 (0-10S, 90W-80W) de enero a junio del 2016, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2015/16	MSE	0.124	0.161	0.851	1.457	2.377	6.014	1.830
	RMSE	0.352	0.401	0.922	1.207	1.542	2.452	1.146
	<i>RMSPE</i> ⁴	<i>0.18</i>	<i>0.31</i>	<i>0.73</i>	<i>5.56</i>	<i>5.49</i>	<i>84.94</i>	<i>16.20</i>
	MAE	0.271	0.336	0.820	1.055	1.344	2.193	1.003
	<i>MAPE</i> ⁴	<i>0.15</i>	<i>0.26</i>	<i>0.64</i>	<i>3.02</i>	<i>3.50</i>	<i>19.36</i>	<i>4.49</i>

⁴Porcentajes

En el caso de la métrica estadística de MAPE la Tabla 18 muestra que en todos los meses hay buena significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Una vez obtenido los pronósticos de enero a junio del 2016 de manera espacial y temporal (Figuras 57 y 58), se calculan las métricas estadísticas solo de las regiones de interés (región Niño 3.4 y Niño 1+2) de la data pronosticada grillada y observada grillada (Tablas 19 y 20), estas métricas estadísticas se estiman para cada celda de la cuadrícula individualmente.

Para el caso de la región Niño 3.4 (Tabla 18) se obtienen valores promedio de RMSPE de 0.52 por ciento (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), y MAPE de 0.40 por ciento (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003). Para la región Niño 1+2 (Tabla 19) se observa que el último mes (junio 2016) presenta un RMSPE de 84.94 por ciento (considerado como MALO), el resto de meses presenta un RMSPE <10 por ciento, el cual es considerado como EXCELENTE precisión del pronóstico, en el caso de MAPE para la región Niño 1+2 se observa que el último mes (junio 2016) presenta un MAPE de 19.36 por ciento (10 por ciento <MAPE <= 20 por ciento, considerado como BUENA precisión del pronóstico), el resto de meses presenta un MAPE <10 por ciento, el cual es considerado como EXCELENTE precisión del pronóstico, según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

En general, para el pronóstico de enero a junio a diciembre del 2016 en las regiones Niño 3.4 y Niño 1+2, se observa que en la mayoría de meses las anomalías de la TSM pronosticadas y observadas tienen buena significancia estadística.

Así también se hizo el análisis de correlación de Pearson para las ATSM pronosticado y observado para los meses más representativos (de mayor correlación significativa), esto fue para los tres primeros meses de enero a marzo del 2016, en la Figura 59 se muestra para el área de estudio (latitud 10°S–10°N y longitud 140°E–80°W) para los dos primeros meses una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), el tercer mes de pronóstico

muestra una correlación FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo en los tres primeros meses.

Para la región Niño 3.4, los resultados de correlación de Pearson (Figura 60) de los dos primeros meses de pronóstico muestran una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), el tercer mes de pronóstico muestran una correlación FUERTE ($r > 0.6$, según Tabla 3) indicando significancia del modelo en la región Niño 3.4 en los tres primeros meses.




Figura 59: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W




Figura 60: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 3.4 (5N-5S, 170W-120W)

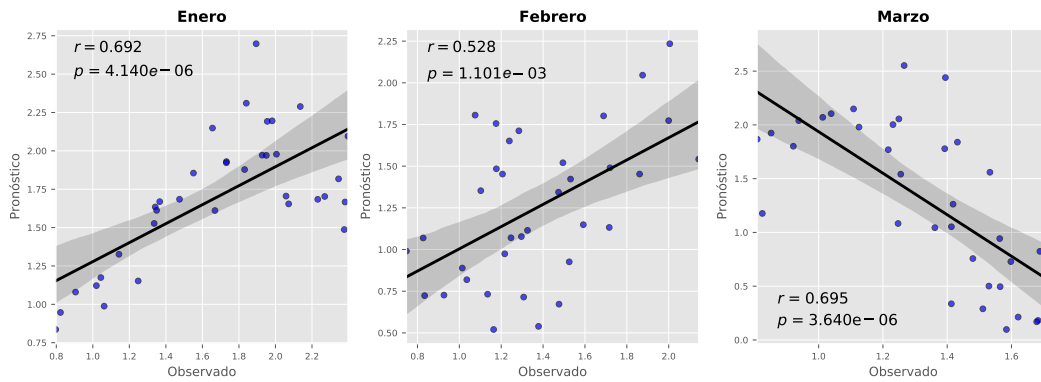


Figura 61: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2016 mejor correlacionados, en etapa de prueba del evento Niño 2015/16 en la región Niño 1+2 (0-10S, 90W-80W)

Para la región Niño 1+2, los resultados de correlación de Pearson (Figura 61) muestran que los dos primeros meses se tiene una correlación FUERTE ($r > 0.6$, según Tabla 3), y para el tercer mes una correlación FUERTE negativa ($r < -0.6$, según Tabla 3), indicando significancia del modelo en la región Niño 1+2 en los tres primeros meses.

Se detallan los resultados también mostrando la evolución temporal de la ATSM de data pronosticada y observada desde julio 2015 a junio 2016 en latitud promedio de 10°S – 10°N y longitudes desde 140°E – 80°W (Figura 62). En la Figura 62b de datos observados se muestran anomalías positivas en la longitud 180°E – 80°W desde julio 2015 hasta mayo 2016, con picos de anomalía en diciembre 2015 en la longitud 140°W – 120°W y setiembre 2015 en la longitud 90°W – 80°W , pero en comparación con el Niño 1982/83 y 1997/98, se presentó anomalías más frías de la TSM en el oeste del pacifico central; esto fue especialmente notable con valores máximos de agosto a octubre del 2015 (Figura 62b).

En el caso de la Figura 62a que son datos pronosticados se observa anomalías positivas en la longitud 180°E – 80°W desde julio 2015 hasta febrero 2016, pero con pico de anomalía en octubre 2015 en la longitud 120°W – 80°W y con anomalías casi neutras de marzo 2016 a mayo 2016 en la longitud 120°W – 80°W , así mismo en comparación con el Niño 1982/83 y 1997/98 y los datos observados del Niño 2015/16 (Figura 62b), el pronóstico también presentó anomalías más frías de la TSM en el oeste del pacifico central; esto es notable con valores máximos de agosto a setiembre del 2015 y marzo del 2016 (Figura 62a).

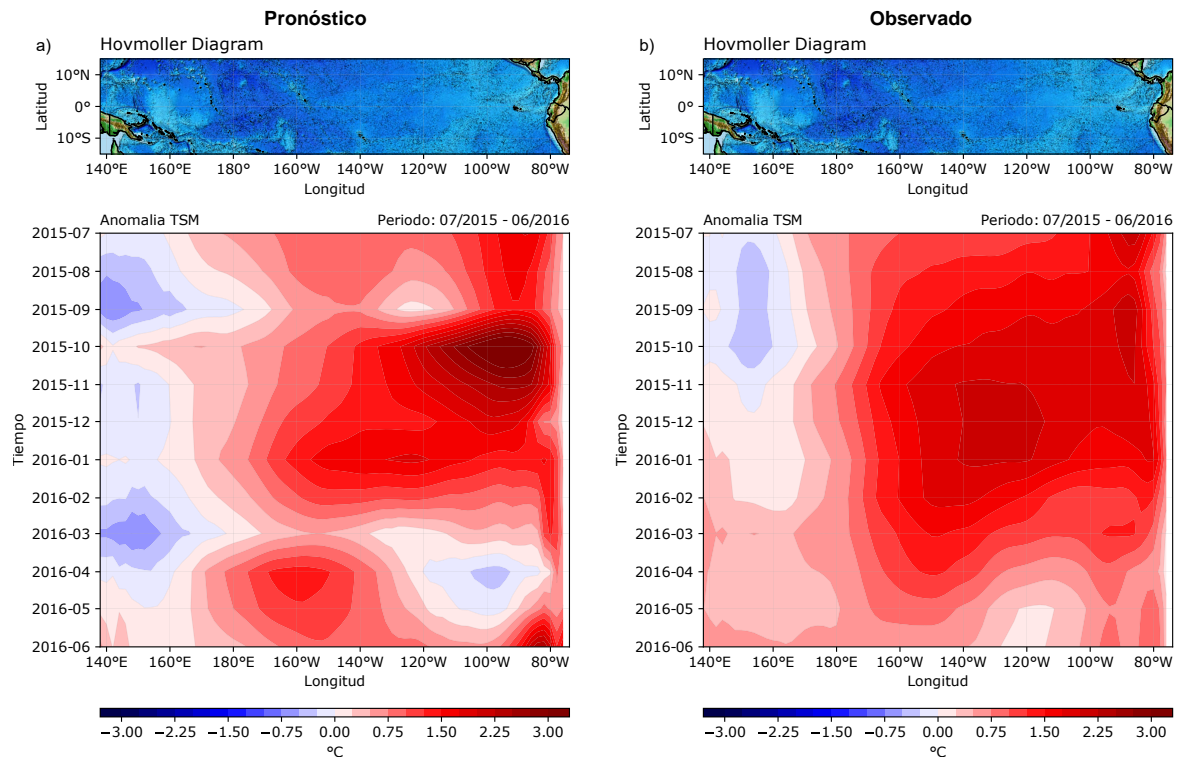


Figura 62: Diagrama de longitud-tiempo (Hovmöller) de ATSM pronosticado (izquierda) y observado (derecha) de julio a junio del 2015/16 en etapa de prueba del Niño 2015/16, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

En las Figuras 63a y 63b se muestran la evolución temporal de la TSM de data pronosticada y observada desde julio 2015 a junio 2016 en latitud promedio de 10°S–10°N y longitudes desde 140°E–80°W, se observa similar comportamiento temporal de las temperaturas en lo pronosticado y observado, con mayores temperaturas en la longitud 140°E–140°W y va decreciendo paulatinamente la temperatura hasta la longitud 80°W, en la Figura 63b hay un pico de incremento de temperatura en enero 2016 a mayo 2016 en la longitud 120°W–80°W, y en la Figura 63a el pico es mucho menor de valores de temperatura en enero 2016 a marzo 2016 en la longitud 100°W–80°W.

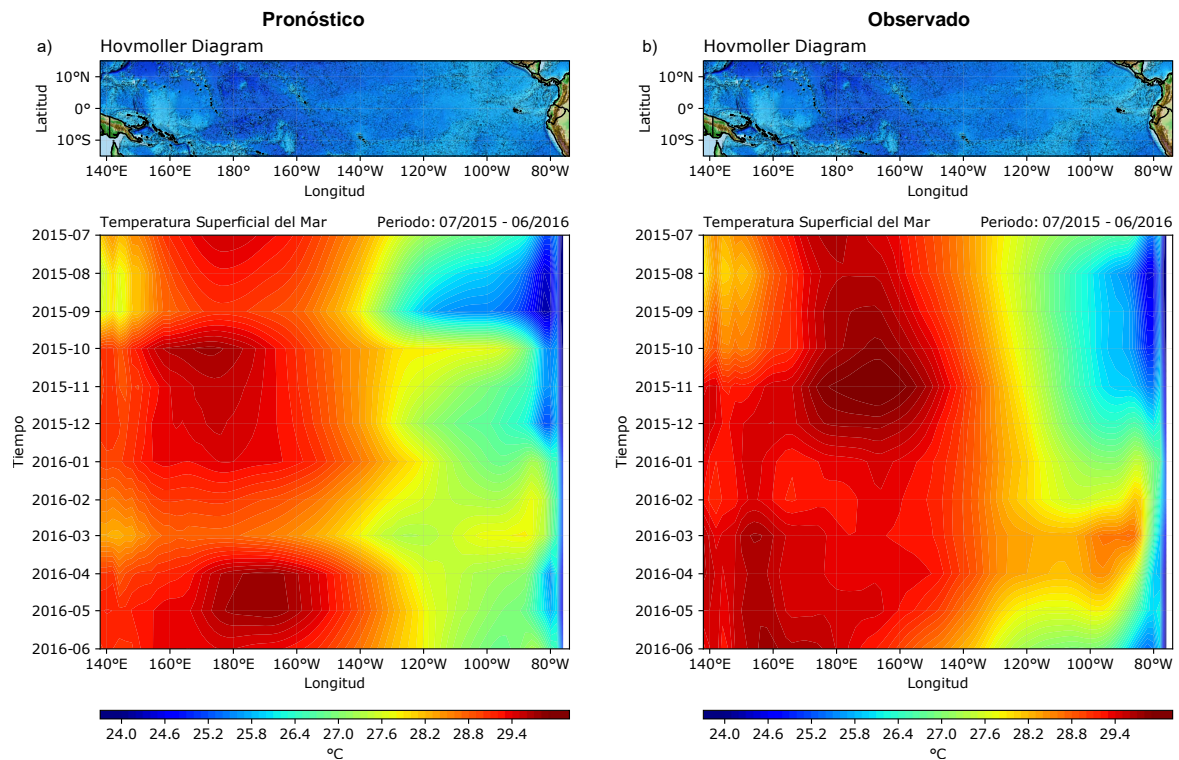


Figura 63: Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de julio a junio del 2015/16 en etapa de prueba Niño 2015/16, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

Así mismo para una mayor comprensión se calculan los valores promedios de las ATSM solo para la región Niño 3.4 y Niño 1+2 de la data pronosticada y observada para mostrarse temporalmente (Figura 64).

En la Figura 64 se muestra la comparación entre los datos observados y pronosticados con 6 meses de anticipación para la región Niño 3.4 y Niño 1+2 en series de tiempo, en las Figuras 64a y 64b se presentan de julio a diciembre del 2015 y de enero a junio del 2016 respectivamente para la región Niño 3.4, la serie de tiempo mostrada en la Figura 64a siempre subestima el valor observado, mientras que en la Figura 64b subestima de enero a marzo del 2016 y posteriormente sobrestima hasta junio 2016.

En las Figuras 64c y 64d se muestran de julio a diciembre del 2015 y de enero a junio del 2016 respectivamente para la región Niño 1+2, la serie de tiempo mostrada en la Figura 64c en octubre 2015 se observa una sobrestimación de la data pronosticada respecto

a lo observado y posteriormente en diciembre 2015 una subestimación. La serie de tiempo mostrada en la Figura 64d subestima en abril del 2016 y sobrestima en junio 2016.

Se observa de acuerdo a los resultados de las Figuras 64a y 64b pertenecientes a la región Niño 3.4 que se clasifica el pronóstico como Niño muy fuerte (basado en la sección 2.3 - ONI), y de las Figuras 64c y 64d para la región Niño 1+2, como Niño Fuerte (basado en la sección 2.3 - ICEN), tal y como también se presentó con los datos observados.

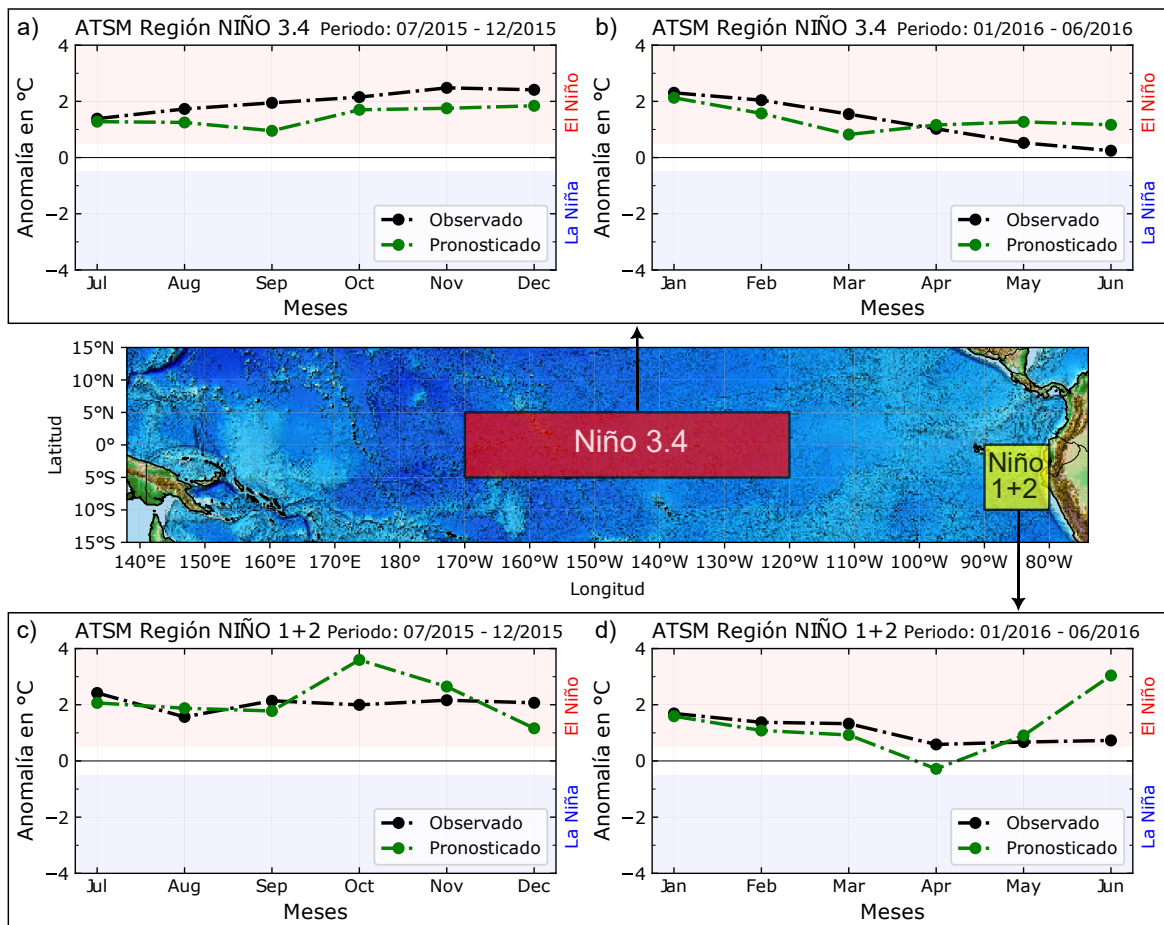


Figura 64: ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niño Extraordinario 2015/16. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

4.4.2. Pronóstico de las ATSM y TSM del Niño costero 2017

Takahashi y Martinez (2019), mencionan en su artículo científico que El evento del Niño de 1925, es considerado como el tercero más fuerte en el siglo XX en el Pacífico oriental según sus impactos ocurridos, asociándose con fuertes lluvias e inundaciones en la costa norte de

Perú de febrero a abril de 1925, así mismo Takahashi (2017), menciona que este evento del año de 1925 tuvo muchas similitudes con el evento del Niño Costero del 2017. Es por tal razón que se analiza y pronostica este evento 2017, teniendo en cuenta que el modelo ConvLSTM ya aprendió en la etapa de entrenamiento del evento similar denominado Niño Costero de 1925 (vale recordar que la etapa de entrenamiento fue de 1854 a 1997).

El evento Niño Costero 2017 solo tuvo ATSM en la Pacífico Oriental (Takahashi 2017) dentro de la región Niño 1+2, el cual será analizado en esta sección. En la Figura 65 se muestran las TSM de los datos pronosticados y observados durante el periodo de noviembre a abril del 2016/17, para tener un mayor entendimiento de la evolución del Niño costero pronóstico se expresará en ATSM tal como muestra la Figura 66, valga recordar que las anomalías se calculan con respecto a la climatología de 1981-2010.

Las ATSM de data pronosticada y observada (Figura 66), para el pronóstico del Niño Costero 2017, el cual se llevó a cabo con seis meses de anticipación del evento, en este ejemplo, se alimenta al modelo con información de mayo a octubre del 2016, se muestran pronósticos de noviembre a abril del 2016/17 (meses de evolución del Niño Costero 2017), para su comparación y compresión entre lo pronosticado y lo observado se utiliza las métricas estadísticas mencionadas anteriormente el cual se muestran los resultados en la Tabla 21 en el océano Pacífico ecuatorial (latitud 10°S–10°N y longitud 140°E–80°W), del cual se observa que el RMSPE de los meses de noviembre, diciembre del 2016, enero y abril del 2017 muestran una EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para febrero y marzo del 2017 es BUENA precisión del pronóstico (10 por ciento <RMSPE <= 20 por ciento).

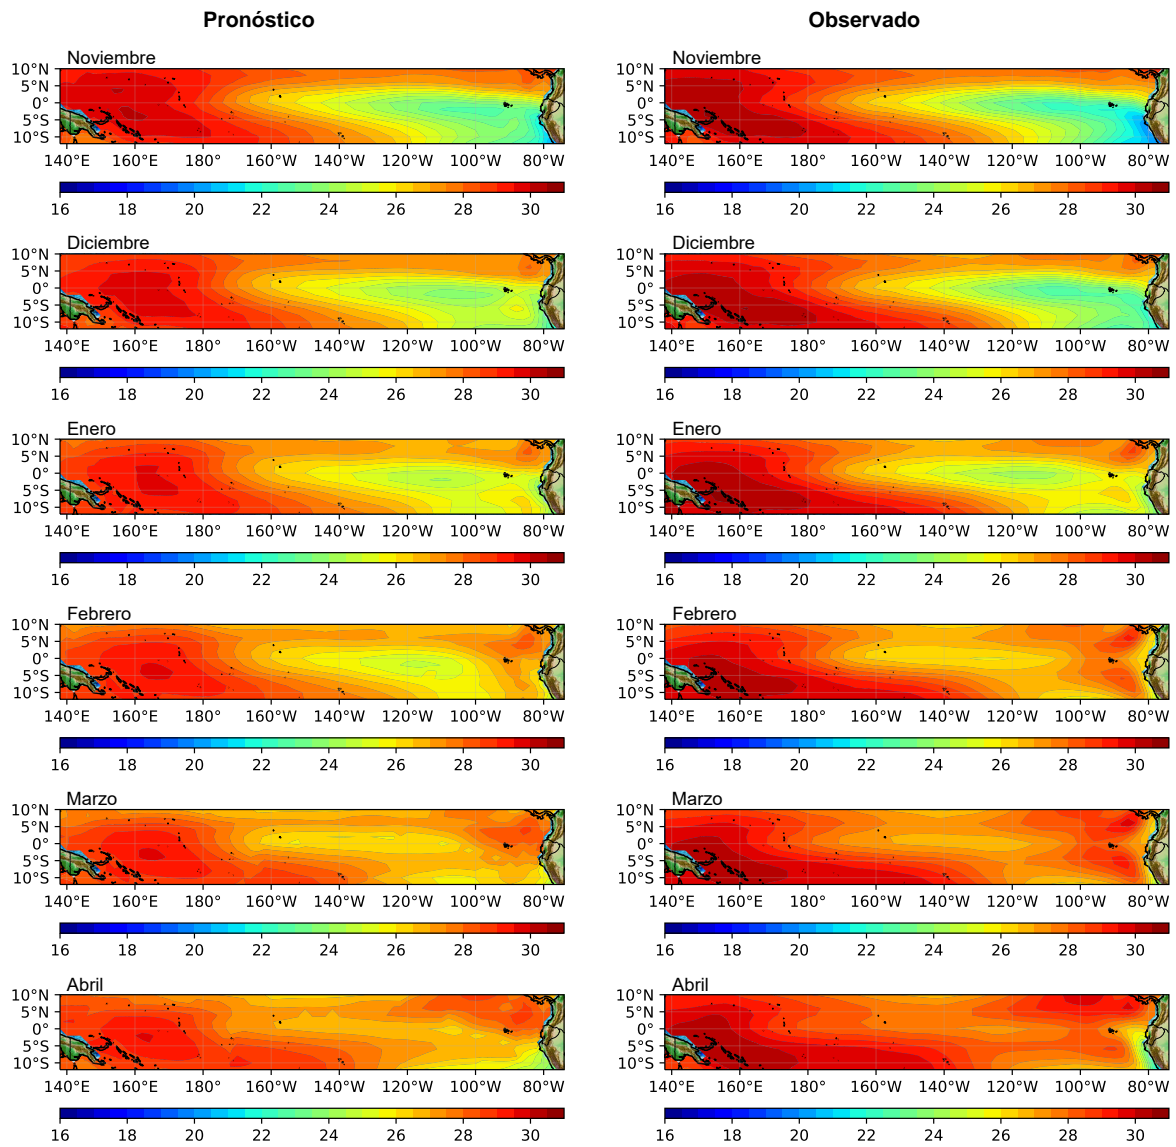


Figura 65: TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

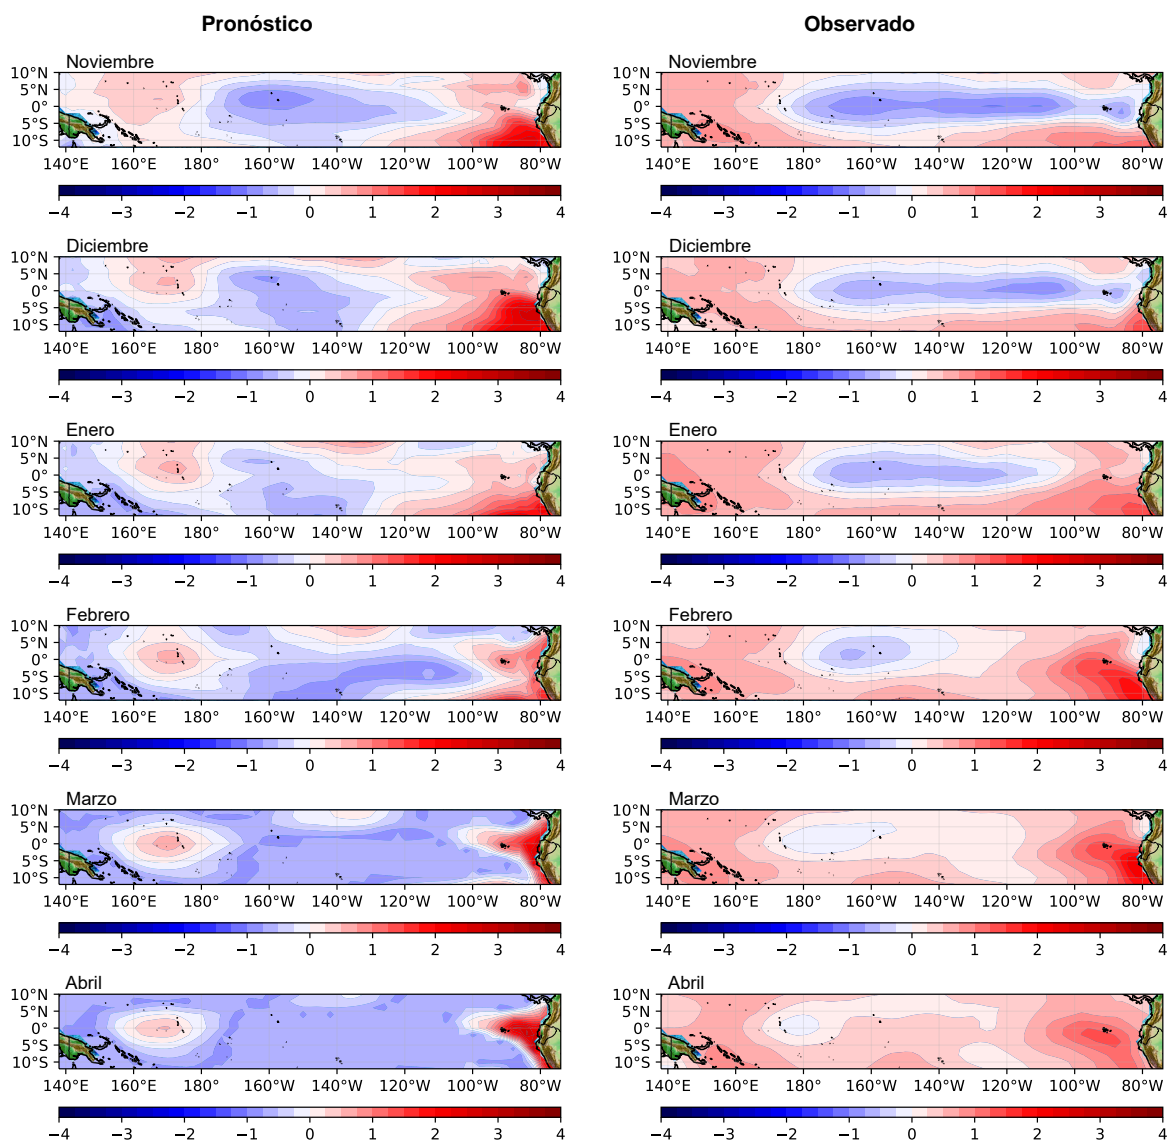


Figura 66: Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

En el caso de la métrica estadística de MAPE la Tabla 21 muestra que en todos los meses hay buena significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Una vez obtenido los pronósticos de noviembre del 2016 a abril del 2017 de manera espacial y temporal (Figuras 65 y 66), se calculan las métricas estadísticas solo de las regiones de interés (región Niño 3.4 y Niño 1+2) de la data pronosticada grillada y observada grillada (Tablas 22 y 23), estas métricas estadísticas se estiman para cada celda de la cuadrícula individualmente.

Tabla 21: Métricas estadísticas del Niño Costero 2017 de noviembre a abril 2016/17, del modelo de pronóstico respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)

NIÑO COSTERO	Métricas Estadísticas	Mes 1 Nov	Mes 2 Dic	Mes 3 Ene	Mes 4 Feb	Mes 5 Mar	Mes 6 Abr	Prom
2016/17	MSE	0.223	0.442	0.391	0.661	0.882	0.976	0.596
	RMSE	0.472	0.665	0.626	0.813	0.939	0.988	0.750
	<i>RMSPE</i> ⁵	<i>5.16</i>	<i>8.21</i>	<i>3.17</i>	<i>11.78</i>	<i>16.06</i>	<i>5.77</i>	8.36
	MAE	0.343	0.507	0.485	0.674	0.825	0.903	0.623
	<i>MAPE</i> ⁵	<i>1.65</i>	<i>2.76</i>	<i>1.46</i>	<i>3.08</i>	<i>5.00</i>	<i>2.72</i>	2.78

Tabla 22: Métricas estadísticas de noviembre a abril del 2016/17 de la región Niño 3.4 (5N-5S, 170W-120W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO COSTERO	Métricas Estadísticas	Mes 1 Nov	Mes 2 Dic	Mes 3 Ene	Mes 4 Feb	Mes 5 Mar	Mes 6 Abr	Prom
2016/17	MSE	0.044	0.101	0.125	0.382	0.492	0.709	0.309
	RMSE	0.210	0.317	0.353	0.618	0.701	0.842	0.507
	<i>RMSPE</i> ⁵	<i>3.13</i>	<i>6.23</i>	<i>2.17</i>	<i>21.67</i>	<i>33.51</i>	<i>3.25</i>	11.66
	MAE	0.175	0.262	0.302	0.481	0.669	0.836	0.454
	<i>MAPE</i> ⁵	<i>0.95</i>	<i>2.19</i>	<i>1.38</i>	<i>6.52</i>	<i>15.16</i>	<i>3.04</i>	4.87

Tabla 23: Métricas estadísticas del Niño Costero 2017 de la región Niño 1+2 (0-10S, 90W-80W) de noviembre a abril del 2016/17, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑO COSTERO	Métricas Estadísticas	Mes 1 Nov	Mes 2 Dic	Mes 3 Ene	Mes 4 Feb	Mes 5 Mar	Mes 6 Abr	Prom
2016/17	MSE	1.595	2.533	0.125	0.726	1.839	2.149	1.494
	RMSE	1.263	1.591	0.353	0.852	1.356	1.466	1.147
	<i>RMSPE</i> ⁵	<i>6.56</i>	<i>6.65</i>	<i>0.41</i>	<i>1.18</i>	<i>0.94</i>	<i>1.57</i>	2.89
	MAE	1.176	1.467	0.294	0.726	1.146	1.334	1.024
	<i>MAPE</i> ⁵	<i>4.20</i>	<i>4.61</i>	<i>0.34</i>	<i>0.70</i>	<i>0.78</i>	<i>1.40</i>	2.01

⁵Porcentajes

Para el caso de la región Niño 3.4 (Tabla 22) se obtiene valores de RMSPE de los meses de noviembre, diciembre del 2016, enero y abril del 2017 dando EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para febrero del 2016 es REGULAR precisión del pronóstico (20 por ciento <RMSPE <= 30 por ciento), y para marzo del 2017 es MALA (RMSPE >30 por ciento), en el caso de la métrica estadística porcentual MAPE nos da EXCELENTE significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003), excepto el mes de marzo nos da BUENA precisión del pronóstico (10 por ciento <MAPE <= 20 por ciento).

Para la región Niño 1+2 (Tabla 23), respecto a la métrica estadística porcentual RMSPE se observa que en todos los meses presenta una EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), para el caso de MAPE para la región Niño 1+2 se observa que mes a mes presenta también una EXCELENTE precisión del pronóstico (MAPE <10 por ciento), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Si bien el análisis de esta sección es para el Niño Costero 2017 (Basados en región Niño 1+2) se analiza también la región Niño 3.4, para ver la calidad y predictibilidad del modelo ConvLSTM, en una región donde no hay evento Niño (sabido es, que no hubo evento Niño en la región Niño 3.4 para el 2017), se muestran resultados óptimos según las métricas estadísticas dadas en la Tabla 22.

Se detallan los resultados también, mostrando la evolución temporal de la ATSM de data pronosticada y observada desde noviembre del 2016 a abril del 2017 en latitud promedio de 10°S–10°N y longitudes desde 140°E–80°W (Figura 67), en la Figura 67b se muestra anomalías positivas iniciando en diciembre 2016 a abril del 2017 en longitud 120°W–80°W.

En el caso de la Figura 67a se observa de anomalías positivas pronosticadas en la longitud 120°W–80°W desde noviembre del 2016 hasta enero del 2017, y decreciendo en longitud 90°W–80°W de febrero a abril del 2017.

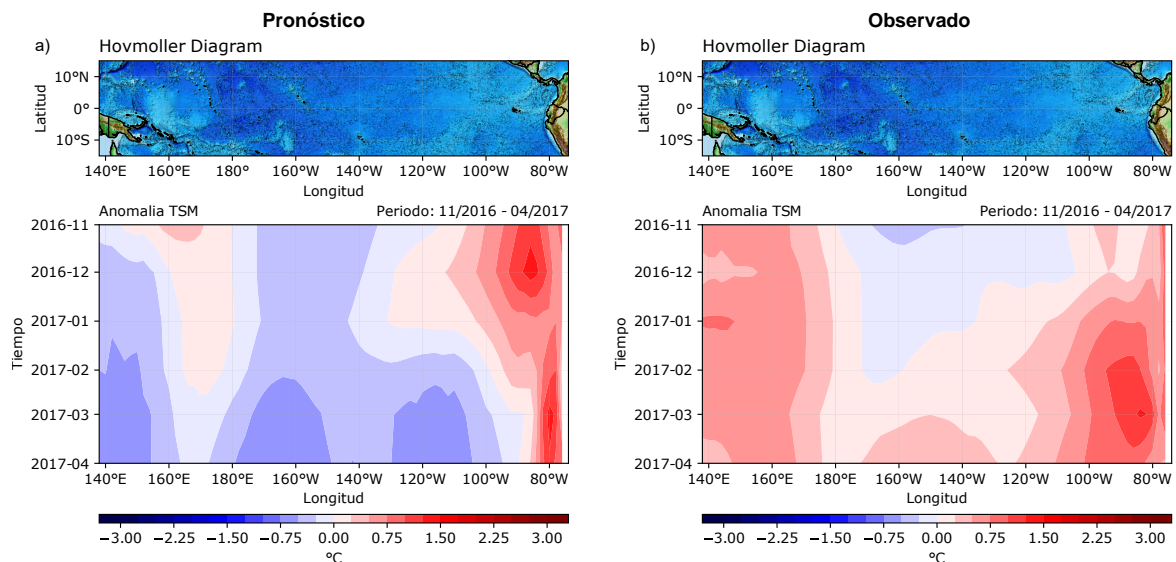


Figura 67: Diagrama de longitud-tiempo (Hovmöller) de Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del Niño Costero 2017, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

También se observa la evolución temporal de la TSM de data pronosticada y observada en la Figura 68 desde noviembre del 2016 a abril del 2017 en latitud promedio de 10°S–10°N y longitudes desde 140°E–80°W, se observa similar comportamiento temporal de las temperaturas en lo pronosticado y observado, en las Figuras 68a y 68b se muestran mayores temperaturas en la longitud 140°E–180° y va decreciendo paulatinamente la temperatura hasta la longitud 80°W, en la Figura 68b hay un pico de incremento de temperatura de febrero a abril del 2017 en la longitud 100°W–80°W, esto será corroborado mejor mostrando la evolución en el tiempo mediante las ASTM.

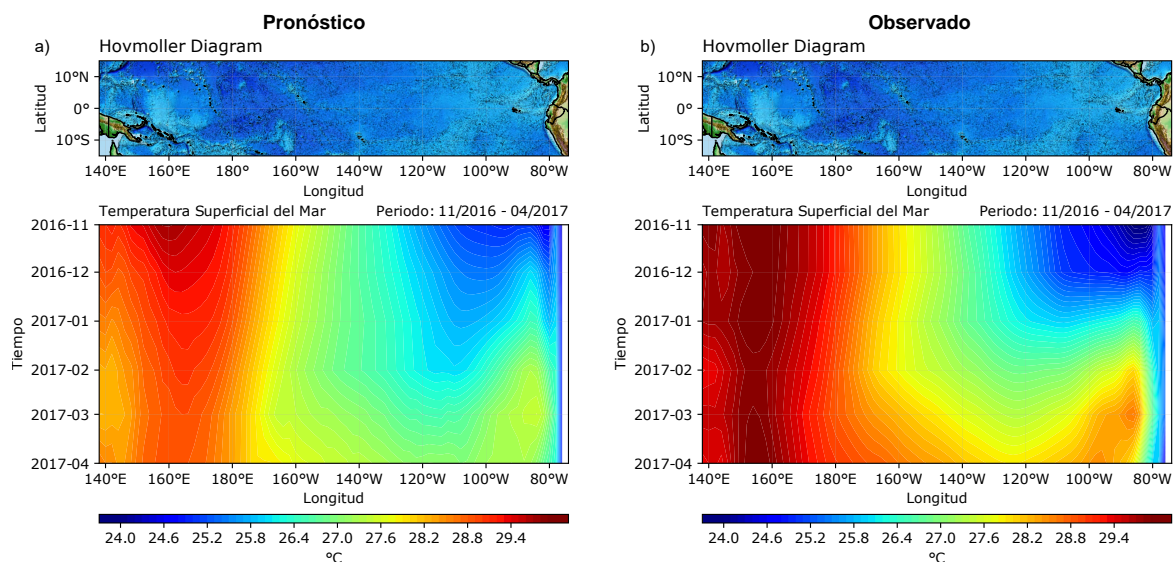


Figura 68: Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de noviembre a abril del 2016/17 en etapa de prueba del Niño Costero 2017, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

Con lo visto anteriormente respecto a la evolución temporal de la TSM y las ATSM del evento 2016/17 se hizo la comparación de los datos pronosticados y observados en series de tiempo para la región Niño 3.4 y Niño 1+2.

En la Figura 69a se presenta la serie de tiempo de noviembre a abril del 2016/17 para la región Niño 3.4, observando una pequeña subestimación del valor observado a partir de febrero a abril del 2017, por lo tanto, si bien el modelo es utilizado para pronosticar eventos extremos de ENOS (Niño o Niña), también pronostica eventos neutros, como es el caso de la región Niño 3.4 para el año 2016/17 (Figura 69a y Tabla 22).

En la Figura 69b se muestra la serie de tiempo de noviembre a abril del 2016/17 para la región Niño 1+2, mostrando de noviembre a diciembre del 2016 una sobrestimación de la data pronosticada respecto a lo observado, y posteriormente en febrero y marzo del 2017 una subestimación de la data pronosticada respecto a lo observado.

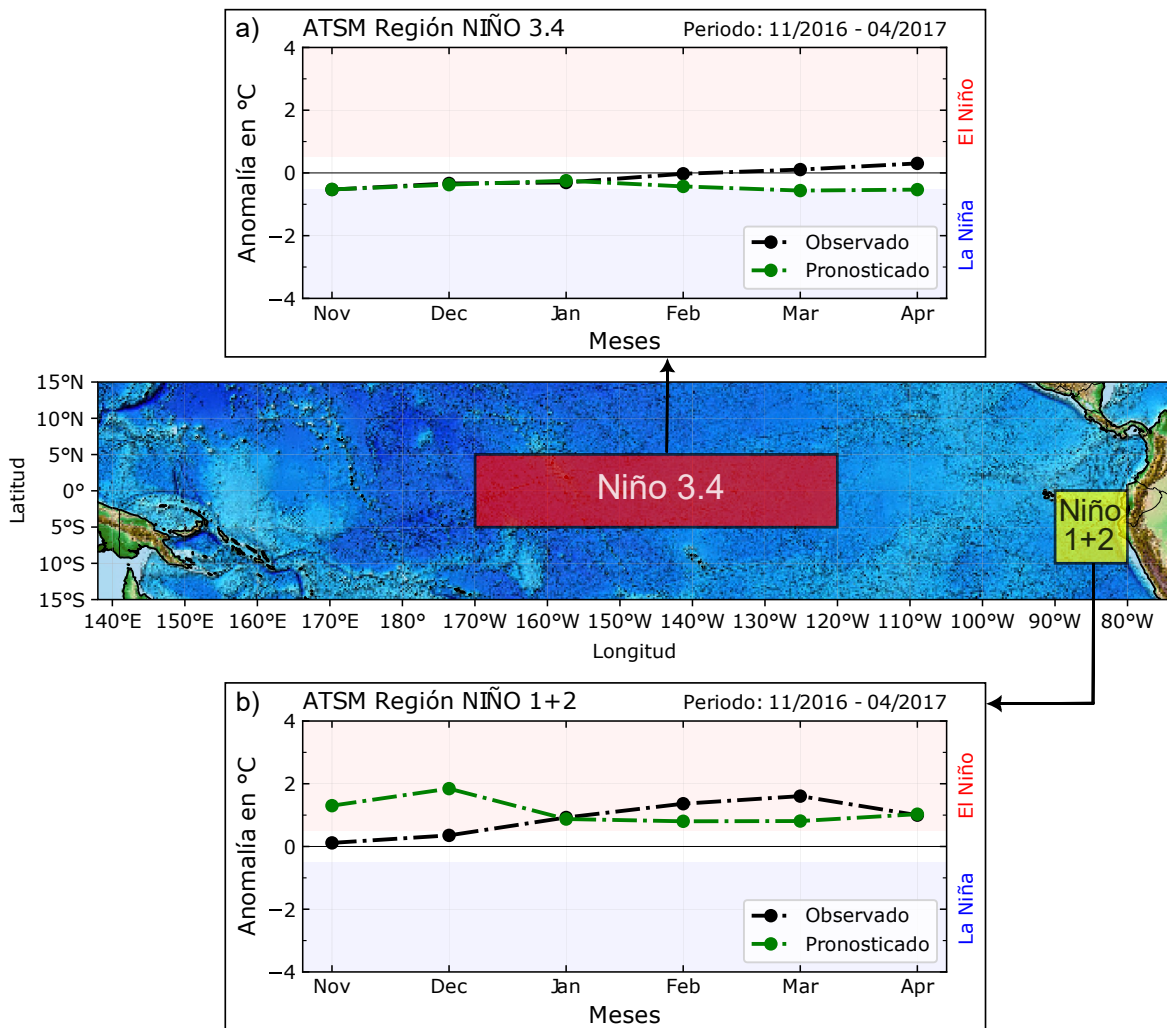


Figura 69: ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niño Costero 2017. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

Se observa de acuerdo a los resultados de la Figura 69a perteneciente a la región Niño 3.4 que se clasifica el pronóstico como Condiciones neutras (Normal) (Basado en la sección 2.3 - ONI), y de la Figura 69b para la región Niño 1+2, como Niño Moderado (Basado en la sección 2.3 - ICEN), tal y como también se presentó con los datos observados.

Así también se hizo el análisis de correlación de Pearson para las ATSM pronosticado y observado como los años anteriores de pronóstico (2015/16), esto fue para los tres primeros meses, de noviembre del 2016 a enero del 2017, en la Figura 70 se muestra para el área de estudio (latitud 10°S–10°N y longitud 140°E–80°W) para el primer mes una correlación FUERTE ($r > 0.6$, según Tabla 3), el resto de meses presenta correlación

DEBIL ($0.2 < r < 0.4$, según Tabla 3). Si bien muestra correlación DÉBIL el segundo y tercer mes, este es por la región Niño 3.4, el cual no hay evento ENOS (el 2017 hubo Niño Costero, esto ubicado en la región Niño 1+2), el cual en la región Niño 3.4 no muestra correlaciones significativas.

Para la región Niño 1+2, los resultados de correlación de Pearson (Figura 71) muestran que el primer y tercer mes se tiene una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), y para el segundo mes una correlación FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo en la región Niño 1+2 en los tres primeros meses. Si bien en el área de estudio (latitud 10°S – 10°N y longitud 140°E – 80°W).




Figura 70: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (noviembre – enero) del 2016/17 mejor correlacionados, en etapa de prueba del evento Niño Costero 2017, en el océano Pacífico ecuatorial latitud 10°S – 10°N y longitud 140°E – 80°W

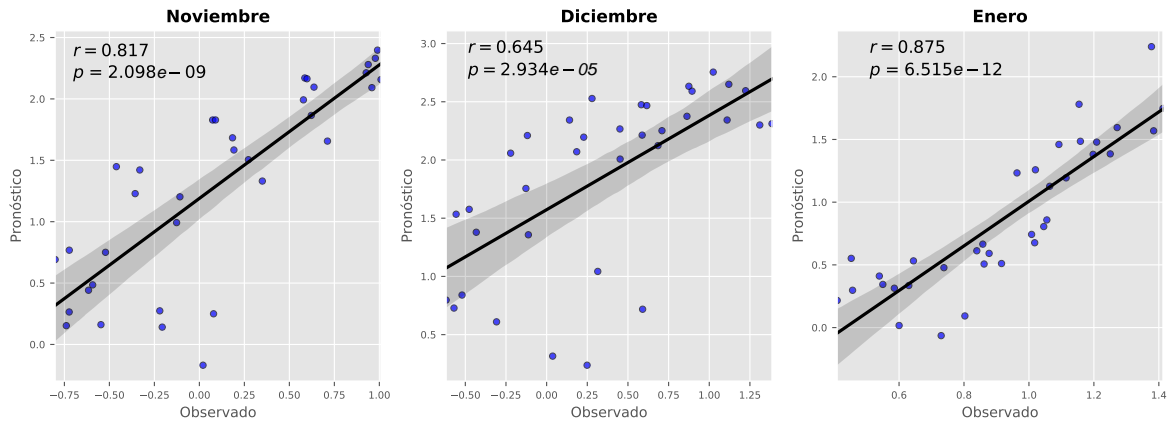


Figura 71: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (noviembre – enero) del 2016/17 mejor correlacionados, en etapa de prueba del evento Niño Costero 2017 en la región Niño 1+2 (0-10S, 90W-80W)

4.4.3. Pronóstico de la ATSM y TSM de la Niña 2022

La Niña que se desarrolló en la segunda mitad del año 2021 se mantiene todavía activa en el Pacífico tropical en el año 2022 (según la NOAA), por lo cual, en esta sección se aborda el pronóstico del evento La Niña 2022 desde enero a junio del 2022. En la Figura 72 se muestra la TSM de los datos pronosticados y observados durante el periodo de enero a junio del 2022, para tener un mayor entendimiento de la evolución de la Niña, los datos observados y pronosticados se expresará en ATSM tal como muestra la Figura 73, valga recordar que las anomalías se calculan con respecto a la climatología de 1991-2020.

Las ATSM de data pronosticada y observada (Figura 73), para el pronóstico de la Niña 2022, el cual se llevó a cabo con seis meses de anticipación del evento, en este ejemplo, se alimenta al modelo con información de julio a diciembre del 2021, y se muestran pronósticos de enero a junio del 2022 (meses de evolución de la Niña 2022), para su comparación y comprensión entre lo pronosticado y lo observado se utilizan las métricas estadísticas mencionadas anteriormente el cual se muestran los resultados en la Tabla 24 en el océano Pacífico ecuatorial (latitud 10°S–10°N y longitud 140°E–80°W).

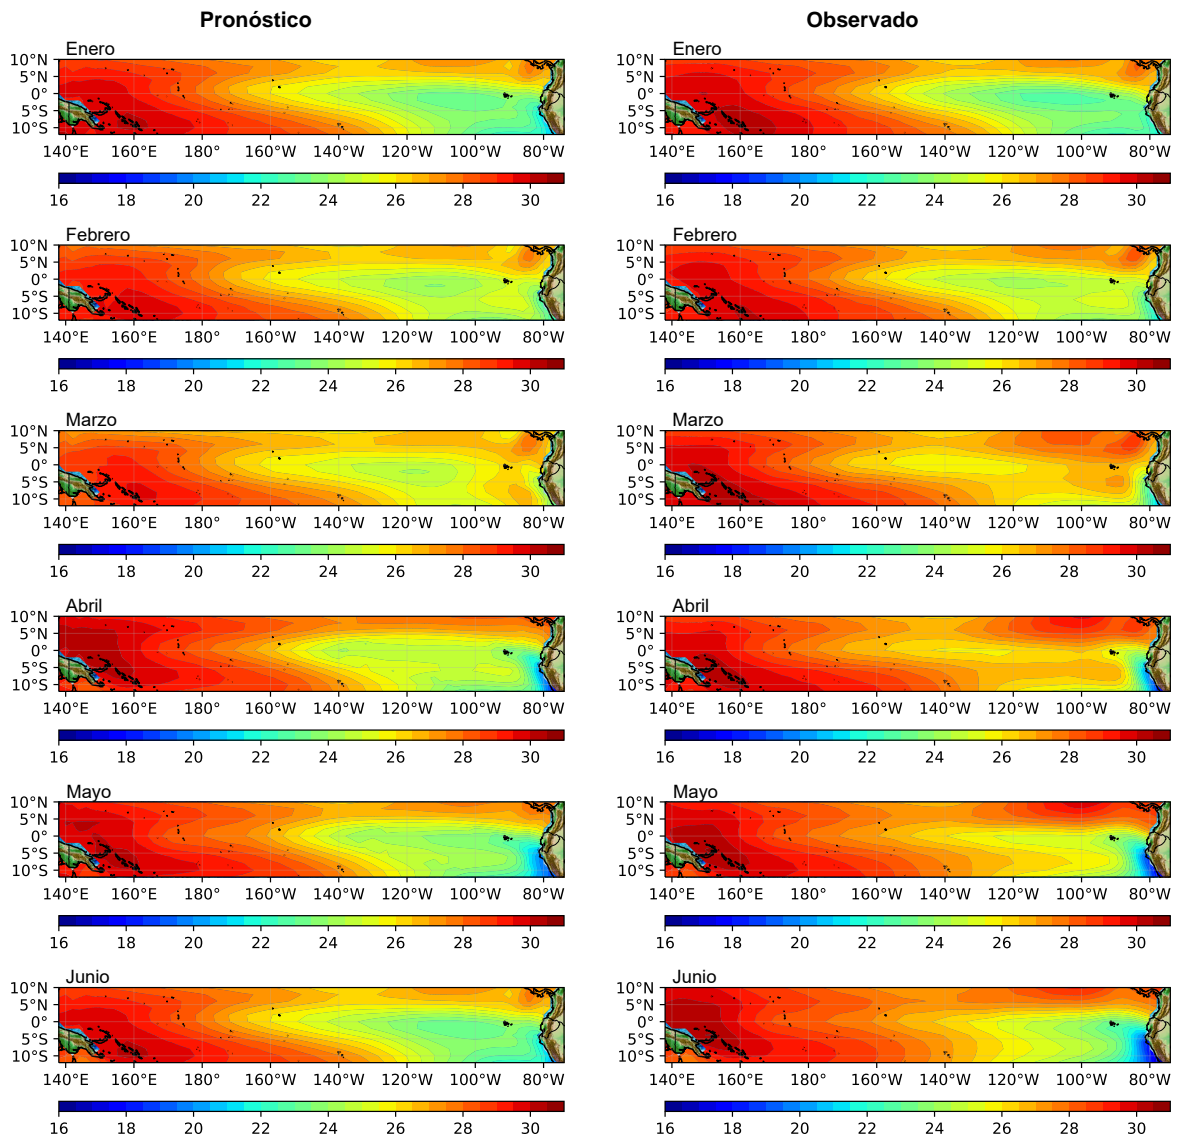


Figura 72: TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba del evento Niña 2022, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

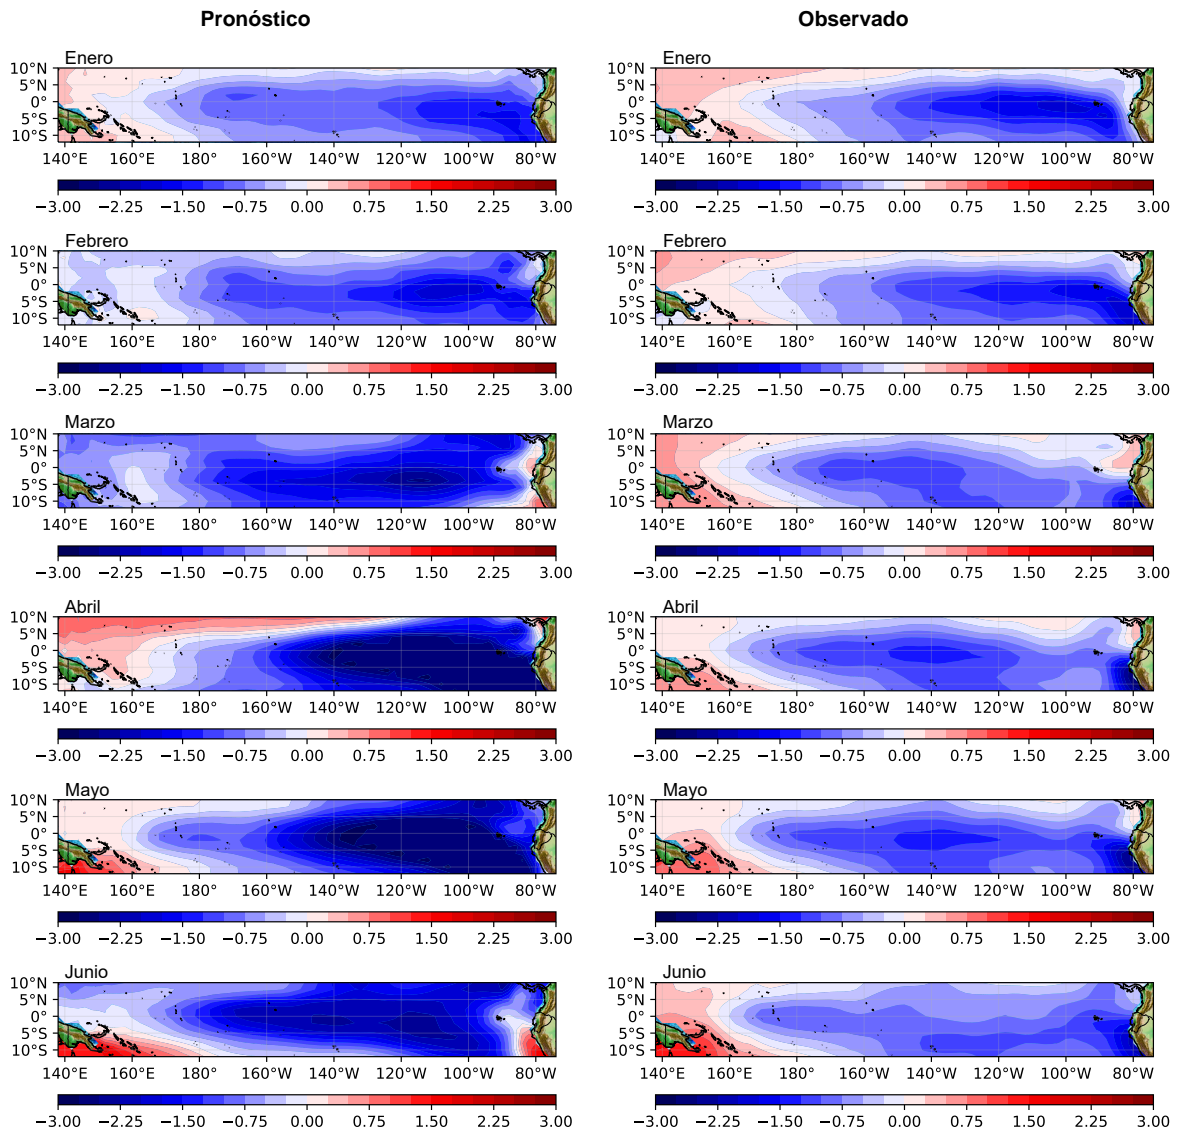


Figura 73: Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W

En la Tabla 24, se observa que el RMSPE del mes de enero, febrero y junio muestra un EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), mientras para marzo del 2022 es BUENA precisión del pronóstico (10 por ciento <RMSPE <= 20 por ciento), para abril y mayo del 2022 es REGULAR precisión del pronóstico (20 por ciento <RMSPE <= 30 por ciento).

En el caso de la métrica estadística de MAPE la Tabla 24 se muestra que en todos los meses hay buena significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.*

2003).

Una vez obtenido los pronósticos de enero a junio del 2022 de manera espacial y temporal (Figuras 72 y 73), se calculan las métricas estadísticas solo de las regiones de interés (región Niño 3.4 y Niño 1+2) de la data pronosticada grillada y observada grillada (Tablas 25 y 26), estas métricas estadísticas se estiman para cada celda de la cuadrícula individualmente.

Para el caso de la región Niño 3.4 (Tabla 25) se obtienen valores de RMSPE en todos los meses buena significancia estadística ya que los valores se aproximan a cero (RMSPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), en el caso de la métrica estadística porcentual MAPE también nos da EXCELENTE significancia estadística ya que los valores se aproximan a cero (MAPE <10 por ciento, es EXCELENTE precisión del pronóstico), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Para la región Niño 1+2 (Tabla 26), respecto a la métrica estadística porcentual RMSPE se observa que en todos los meses presenta una EXCELENTE precisión del pronóstico (RMSPE <10 por ciento), según la Tabla 4 (Jamieson *et al.* 1991; Li *et al.* 2013), para el caso de MAPE para la región Niño 1+2 se observa también que mes a mes presenta también una EXCELENTE precisión del pronóstico (MAPE <10 por ciento), según la Tabla 5 (Lewis 1982; Chen *et al.* 2003).

Así también se hizo el análisis de correlación de Pearson para las ATSM pronosticado y observado para los meses más representativos (de mayor correlación significativa), esto fue para los tres primeros meses de enero a marzo del 2022, en la Figura 74 se muestra para el área de estudio (latitud 10°S–10°N y longitud 140°E–80°W) para los dos primeros meses una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), el tercer mes de pronóstico muestra una correlación FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo en los tres primeros meses.

Tabla 24: Métricas estadísticas de La Niña 2022 de enero a junio 2022, del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula, en el océano Pacífico ecuatorial (10°S–10°N y 140°E–80°W)

NIÑA	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2022	MSE	0.082	0.140	0.772	1.012	0.820	0.900	0.621
	RMSE	0.287	0.374	0.879	1.006	0.905	0.949	0.733
	<i>RMSPE</i> ⁶	<i>7.17</i>	<i>8.98</i>	<i>13.99</i>	<i>24.50</i>	<i>27.42</i>	<i>7.43</i>	<i>14.92</i>
	MAE	0.229	0.298	0.728	0.822	0.623	0.749	0.575
	<i>MAPE</i> ⁶	<i>1.42</i>	<i>3.33</i>	<i>5.34</i>	<i>10.18</i>	<i>5.23</i>	<i>2.30</i>	<i>4.63</i>

Tabla 25: Métricas estadísticas de La Niña 2022 de enero a junio de la región Niño 3.4 (5N-5S, 170W-120W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑA	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2022	MSE	0.096	0.073	0.434	0.939	0.937	1.475	0.659
	RMSE	0.310	0.271	0.659	0.969	0.968	1.215	0.732
	<i>RMSPE</i> ⁶	<i>1.93</i>	<i>0.97</i>	<i>0.82</i>	<i>1.07</i>	<i>0.95</i>	<i>1.70</i>	<i>1.24</i>
	MAE	0.266	0.215	0.559	0.816	0.773	1.171	0.633
	<i>MAPE</i> ⁶	<i>0.63</i>	<i>0.47</i>	<i>0.66</i>	<i>0.85</i>	<i>0.74</i>	<i>1.61</i>	<i>0.83</i>

Tabla 26: Métricas estadísticas de La Niña 2022 de enero a junio de la región Niño 1+2 (0-10S, 90W-80W), del modelo de pronóstico con respecto a valores verdaderos de ATSM promediados en todas las celdas de la cuadrícula

NIÑA	Métricas Estadísticas	Mes 1 Ene	Mes 2 Feb	Mes 3 Mar	Mes 4 Abr	Mes 5 May	Mes 6 Jun	Prom
2022	MSE	0.320	0.096	0.787	1.459	0.661	2.913	1.039
	RMSE	0.566	0.309	0.887	1.208	0.813	1.707	0.915
	<i>RMSPE</i> ⁶	<i>3.42</i>	<i>0.23</i>	<i>3.37</i>	<i>1.46</i>	<i>0.75</i>	<i>0.99</i>	<i>1.70</i>
	MAE	0.410	0.225	0.677	1.044	0.720	1.370	0.741
	<i>MAPE</i> ⁶	<i>1.51</i>	<i>0.16</i>	<i>1.78</i>	<i>1.17</i>	<i>0.58</i>	<i>0.86</i>	<i>1.01</i>

⁶Porcentajes

Para la región Niño 3.4, los resultados de correlación de Pearson (Figura 75) de los dos primeros meses de pronóstico muestran una correlación MUY FUERTE ($r > 0.8$, según Tabla 3), el tercer mes de pronóstico muestran una correlación MODERADA ($r > 0.4$, según Tabla 3), indicando significancia del modelo en la región Niño 1+2 en los dos primeros meses.

Para la región Niño 1+2, los resultados de correlación de Pearson (Figura 76) muestran que solo dos primeros meses se tiene una correlación FUERTE ($r > 0.6$, según Tabla 3), indicando significancia del modelo en la región Niño 1+2 en los dos primeros meses.




Figura 74: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2022 mejor correlacionados, en etapa de prueba del evento La niña 2022, en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W




Figura 75: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres primeros meses (enero – marzo) del 2022 mejor correlacionados, en etapa de prueba del evento La Niña 2022 en la región Niño 3.4 (5N-5S, 170W-120W)




Figura 76: Diagrama de dispersión y correlación entre las ATSM pronosticado y observado de los tres dos meses (enero – febrero) del 2022 mejor correlacionados, en etapa de prueba del evento La Niña 2022 en la región Niño 1+2 (0-10S, 90W-80W)

Se detallan los resultados también mostrando la evolución temporal de la ATSM de data pronosticada y observada desde enero a junio del 2022 en latitud promedio de 10°S–10°N y longitudes desde 140°E–80°W (Figura 77). En la Figura 77b se muestra anomalías negativas a lo largo de los meses analizados en longitud 170°W–80°W. En el caso de la Figura 77a se observa anomalías negativas pronosticadas en la longitud 170°W–80°W desde enero a junio del 2022, con mayores valores de marzo a junio del 2022 en longitud 140°W–80°W.

También se observa la evolución temporal de la TSM de data pronosticada y observada en la Figura 78 desde enero a junio del 2022 en latitud promedio de 10°S–10°N y longitudes desde 140°E–80°W, se observa similar comportamiento temporal de las temperaturas en lo pronosticado y observado, en las Figuras 78a y 78b se muestran mayores temperaturas en la longitud 140°E–160°W y va decreciendo paulatinamente la temperatura hasta la longitud 80°W en la Figura 78b.

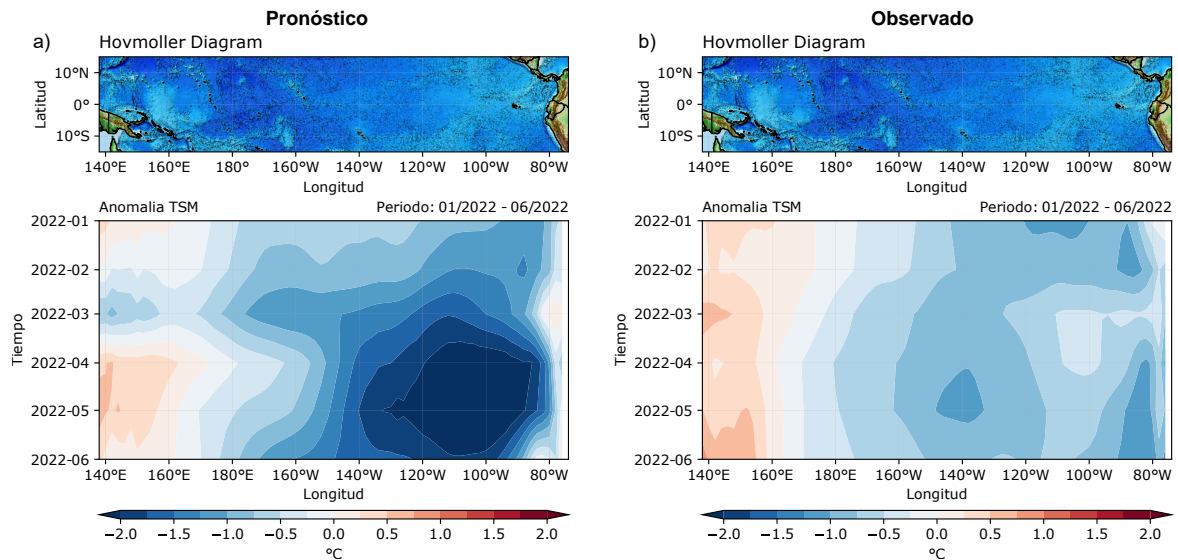


Figura 77: Diagrama de longitud-tiempo (Hovmöller) de Anomalías de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

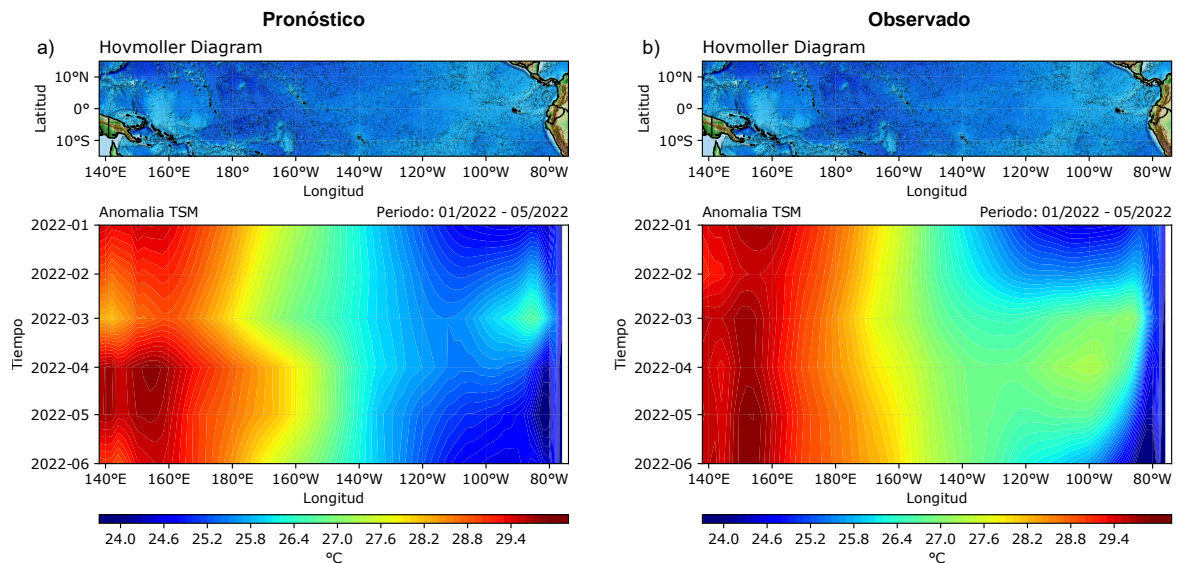


Figura 78: Diagrama de longitud-tiempo (Hovmöller) de la TSM pronosticado (izquierda) y observado (derecha) de enero a junio del 2022 en etapa de prueba, en el océano Pacífico ecuatorial promedio de latitud 10°S–10°N y a lo largo de la longitud 140°E–80°W

Con lo visto anteriormente respecto a la evolución temporal de la TSM y las ATSM del evento 2022 se hizo la comparación de los datos pronosticados y observados en series de tiempo para la región Niño 3.4 y Niño 1+2 (Figura 79).

En la Figura 79a se presenta la serie de tiempo de enero a junio del 2022 para la región Niño 3.4, observando una pequeña subestimación del valor observado a partir de marzo a junio del 2022.

En la Figura 79b se muestra la serie de tiempo de enero a junio del 2022 para la región Niño 1+2, mostrando que para abril a junio del 2022 una subestimación de la data pronosticada respecto a lo observado.

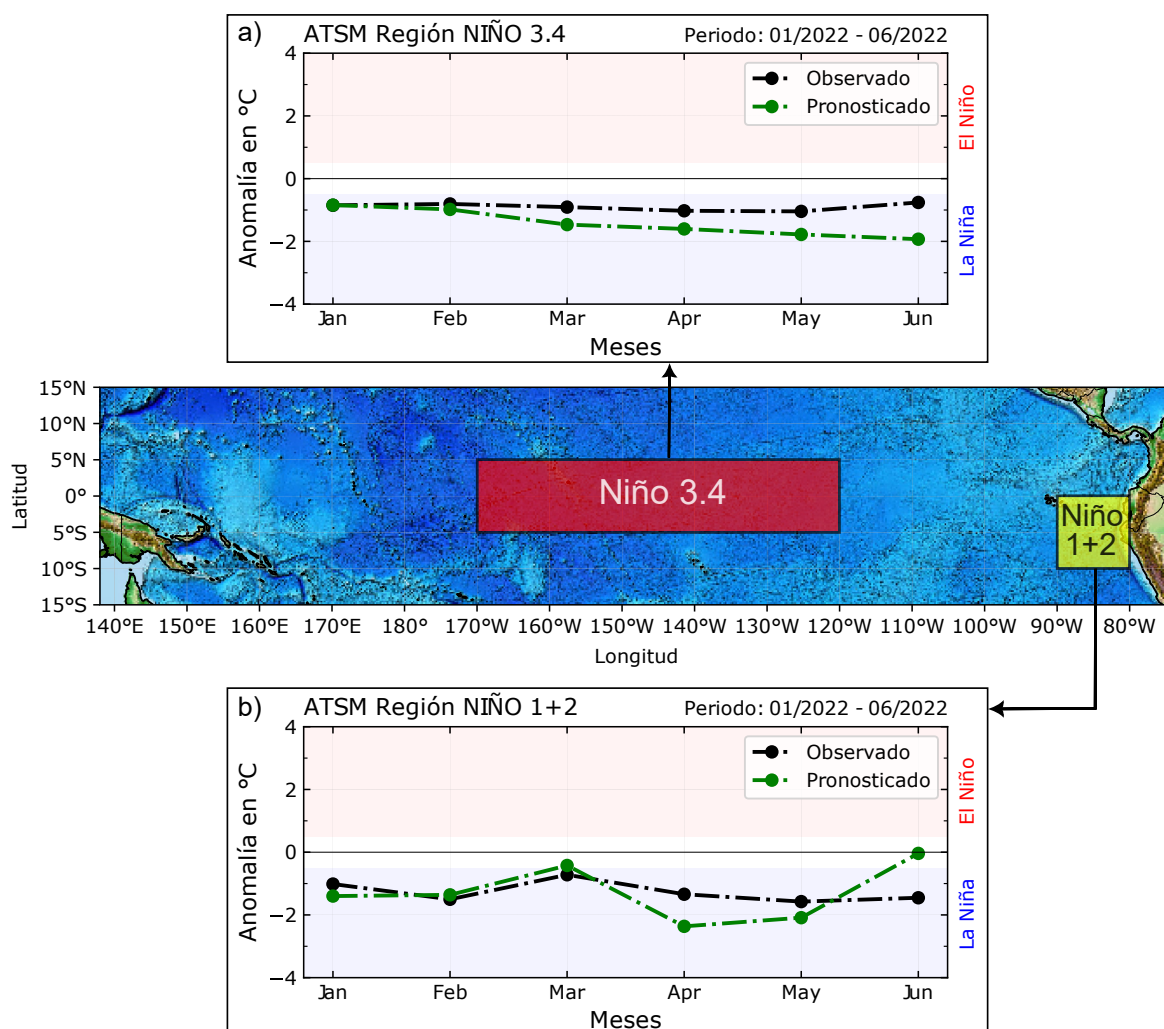


Figura 79: ATSM observado y pronosticado de la región Niño 3.4 (superior) y Niño 1+2 (inferior) con 6 meses de anticipación para el evento Niña 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

Se observa de acuerdo a los resultados de la Figura 79a perteneciente a la región Niño 3.4

que clasifica el pronóstico como Niña Moderada (Basado en la sección 2.3 - ONI), y de la Figura 79b para la región Niño 1+2, como también Niña Moderada (Basado en la sección 2.3 - ICEN), tal y como también se presentó con los datos observados.

4.5. COMPARACIÓN Y EVALUACIÓN DEL MODELO DE RED NEURONAL CON MODELOS CLIMÁTICOS DINÁMICOS Y ESTADÍSTICOS A NIVEL GLOBAL

Se pretende evaluar y comparar visualmente el modelo ConvLSTM con modelos dinámicos y estadísticos a nivel global, en función de series de tiempo y grillado, sabiendo que, todos los modelos muestran la ATSM como producto final para su evaluación y evolución de ENOS.

Los modelos de pronósticos en su mayoría nos muestran valores de la media móvil de tres meses consecutivos de las ATSM, por lo tanto, se utiliza el mismo criterio, donde a los valores mensuales se recalcula en medias móviles de tres meses consecutivos con la finalidad de reducir la variabilidad mensual y obtener series que permitan detectar mejor la señal del ENOS.

Se muestra la evaluación y comparación en la región Niño 3.4 y Niño 1+2, en el caso de la región Niño 3.4, se usa la recopilación de pronósticos dado por IRI (Tabla 2), y para la región Niño 1+2 se busca los modelos más representativos y de acceso en la web con información para la fecha requerida (valores numéricos) para hacer su posterior comparación.

4.5.1. Discusión de pronóstico globales y el modelo ConvLSTM, en la región Niño 3.4

Para esta sección se muestran cuatro periodos de pronóstico y comparación: primero, de julio a diciembre del 2015 (inicio de crecimiento del evento Niño 2015/16), segundo de enero a junio del 2016 (evento Niño 2015/16 en sus valores máximos de la TSM), tercero, de noviembre 2016 a abril del 2017 (Niño Costero 2017) y cuarto de enero a junio del 2022 (La Niña).

4.5.1.1. Año 2015, pronóstico estacional iniciando en julio (JJA) del 2015

La Figura 80 muestra la pluma de pronósticos en meses de inicio y crecimiento de la TSM realizados por modelos estadísticos, dinámicos y el modelo ConvLSTM de las ATSM en la

región Niño 3.4 por nueve periodos de tres meses (Estacional). Cabe recalcar que el modelo ConvLSTM solo pronóstico para seis meses de anticipación, por lo cual en las Figuras 80, 81, 82 y 83 se muestran solo cinco valores debido a que son valores estacionales (promedio de tres meses).

Para una mayor comprensión y evaluación, se dividen los modelos de pronóstico globales en tres partes: primero solo con los modelos dinámicos más representativos (Figura 81), segundo los modelos estadísticos más representativos (Figura 82) y finalmente con el promedio de los modelos dinámicos, estadísticos y promedios globales (Figura 83) con respecto a los valores observados.

Para el pronóstico estacional iniciando en julio (JJA) del 2015, se observa que las habilidades de pronóstico generalmente disminuyen a medida que aumenta el tiempo de entrega (Figura 80), también afirmar que algunos modelos están muy distantes de los valores observados, el caso del modelo NOAA/CDC Linear Inverse desde el mes de octubre (SON) presenta condición Neutra.

En la Figura 81 se observa la pluma de pronósticos de los modelos dinámicos más representativos y el modelo ConvLSTM con respecto a los valores observados, se muestran que los valores del modelo ConvLSTM sigue la tendencia creciente al igual que los valores observados, pero para este pronóstico los modelos dinámicos se aproximas mejor a los valores observados y también siguen la tendencia creciente de sus valores en el tiempo.




Figura 80: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente




Figura 81: Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente




Figura 82: Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente




Figura 83: Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en meses promedio de junio-julio-agosto del 2015. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C respectivamente

4.5.1.2. Año 2016, pronóstico estacional iniciando en enero (DJF) del 2016

La Figura 84 muestra la pluma de pronósticos en meses iniciales (enero y febrero del 2016) de mayores valores máximos de la TSM y en meses en decaimiento de la TSM realizados por modelos estadísticos, dinámicos y el modelo ConvLSTM de las ATSM en la región Niño 3.4 por nueve periodos de tres meses (Estacional). Cabe recalcar que el modelo ConvLSTM solo pronóstico para seis meses de anticipación, por lo cual en las Figuras 84, 85, 86 y 87 se muestra solo cinco valores debido a que son valores estacionales (promedio de tres meses).

Para una mayor comprensión y evaluación, se dividen los modelos de pronóstico globales en tres partes: primero solo con los modelos dinámicos más representativos (Figura 85), segundo los modelos estadísticos más representativos (Figura 86) y finalmente con el promedio de los modelos dinámicos, estadísticos y promedios globales (Figura 87) con respecto a los valores observados.

Para el pronóstico estacional iniciando en enero (DJF) del 2016, se observa que las habilidades de pronóstico generalmente disminuyen a medida que aumenta el tiempo de entrega (Figura 84), también se afirma que algunos modelos están muy distantes de los valores observados, el caso del modelo COLA CCSM3, se observa que para el mes de junio (MJJ) presenta condición La Niña y el valor observado está en condición Normal (Figura 84), o para este mismo mes (MJJ) el modelo Lamont-Doherty presenta condición El Niño, Las diferencias entre los pronósticos de todos los modelos reflejan tanto las diferencias en el diseño conceptual de cada modelo, así como la incertidumbre real en el pronóstico del posible escenario futuro de la TSM.




Figura 84: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 85: Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 86: Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 87: Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

En la Figura 85, se observa la pluma de pronósticos de los modelos dinámicos más representativos y el modelo ConvLSTM con respecto a los valores observados, concluyendo

que el modelo ConvLSTM sigue la tendencia decreciente de los valores observados y tiene un mejor desempeño en el tiempo (para esta fecha) con respecto al modelo NCEP CFSv2, ya que los valores se aproximan más al observado.

Con respecto a los modelos estadísticos más representativos (Figura 86), se observa que el modelo ConvLSTM está más próximo a los datos observados al igual que el modelo NOAA CPC Análisis de correlación Canónica con respecto a los otros modelos como por ejemplo NCEP/CPC Markov.

Y con respecto a los promedios de los modelos dinámico, estadísticos y promedio total (Figura 87) dados por IRI, se observa que el modelo ConvLSTM, es menos próximo que el promedio de modelos con respecto a los valores observados, pero es una comparación con promedios de todos esos modelos, por lo tanto, para esta fecha se observa que el promedio de modelos da un buen resultado de pronóstico para ENOS en la región Niño 3.4. En el promedio de modelos, el pronóstico es menos susceptible en el tiempo a la variación de los valores con respecto a los observados.

Se observa también (Figura 84) que la mayor parte del conjunto de pronósticos de modelos dinámicos, estadísticos y el modelo ConvLSTM emiten de enero (DJF) a mayo (AMJ) del 2016, pronósticos de condiciones El Niño durante el verano austral. El modelo ConvLSTM también pronostica un decaimiento de las condiciones de El Niño a condición Normal durante los meses posteriores a mayo (AMJ) del 2016. En general los modelos dinámicos muestran pronósticos de El Niño más aceptable que los modelos estadísticos (Figuras 85 y 86) y el modelo ConvLSTM muestra pronósticos más aceptables que algunos modelos dinámicos y estadísticos más representativos (Figuras 85 y 86) para el evento Niño 2015/16.

4.5.1.3. Año 2016/17 pronósticos estacional iniciando en noviembre (OND) del 2016

Es sabido y ya mencionado anteriormente en esta investigación que el Año 2016/17 no hubo condición El Niño en la región Niño 3.4, más si hubo en la región Niño 1+2 (Niño Costero 2017). Pero se pronosticó también la región Niño 3.4 para ver la habilidad del modelo con respecto a condiciones normales del pacifico tropical, el cual es mostrado en la Figura 88.

En la Figura 88 se muestra la pluma de pronósticos realizados por modelos estadísticos, dinámicos y el modelo ConvLSTM de las ATSM en la región Niño 3.4 por nueve periodos de tres meses (Estacional). Cabe recalcar que el modelo ConvLSTM solo pronóstico para seis meses de anticipación, por lo cual en las Figuras 88, 89, 90 y 91 se muestran solo cinco valores debido a que son valores estacionales (promedio de tres meses).

Como el caso anterior (Niño 2015/16), para una mayor comprensión y evaluación, se dividen los modelos de pronóstico globales en tres partes: primero solo con los modelos dinámicos más representativos (Figura 89), segundo los modelos estadísticos más representativos (Figura 90) y finalmente con el promedio de los modelos dinámicos, estadísticos y promedios globales (Figura 91) con respecto a los valores observados.

Para el pronóstico estacional iniciando en noviembre 2016, mencionar que las habilidades de pronóstico generalmente disminuyen a medida que aumenta el tiempo de entrega (Figura 88). Se observa en la Figura 88 que algunos modelos (por ejemplo, GFDL CM 2.5 FLOR Coupled Climate model) presentan condiciones extremas en la región Niño 3.4 mostrando condiciones La Niña ($< -0.5^{\circ}\text{C}$) y condiciones El Niño ($> 0.5^{\circ}\text{C}$) para esta fecha establecida, o como los modelos KMA (Korea) SNU model, IOCAS (China) Intermed. Coupled model y Scripps Inst. HCM siempre están en el tiempo en condición La Niña.




Figura 88: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

En la Figura 89 se observa la pluma de pronósticos de los modelos dinámicos más representativos y el modelo ConvLSTM con respecto a los valores observados, se muestra que los valores observados siempre están en la condición normal, el modelo ConvLSTM también sigue esa tendencia, al igual que el modelo ECMWF, el modelo ConvLSTM tiene un buen desempeño visualmente en el tiempo (para esta fecha) con respecto al resto de modelos dinámicos ya que se observa una mayor proximidad a los valores observados.

Con respecto a los modelos estadísticos más representativos (Figura 90) siguen la tendencia de la condición Normal (entre -0.5°C y 0.5°C de la ATSM), así mismo también se muestra que el modelo ConvLSTM los tres primeros meses (Estacionales) tiene muy buen desempeño con respecto a los demás modelos estadísticos por su proximidad a los datos observados y con respecto a los modelos estadísticos, así mismo a lo largo del tiempo el modelo ConvLSTM está en la parte intermedia de estos modelos.




Figura 89: Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 90: Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 91: Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

En el caso de los promedios de los modelos dinámicos, estadísticos y promedio total (Figura 91) dados por IRI, se observa que el modelo ConvLSTM esta con la misma tendencia de estos promedios de modelos en los tres primeros meses y con un decaimiento los dos últimos, así mismo se observa que el promedio de los modelos sigue la tendencia de los datos observados y están en la condición Normal de ENOS.

En general el modelo ConvLSTM para esta fecha dada, muestra pronósticos más aceptables que los modelos dinámicos y estadísticos (Figuras 89 y 90) en los tres primeros meses y pronostica la condición normal de ENOS.

4.5.1.4. Año 2022 pronósticos estacional iniciando en enero (DJF) del 2022

Hasta la fecha de la presente investigación (Año 2022), se está en un evento La Niña, por lo cual se hizo la comparación del modelo ConvLSTM con otros modelos globales para ver la capacidad de pronóstico.

En la Figura 92 se muestra la pluma de pronósticos realizados por modelos estadísticos, dinámicos y el modelo ConvLSTM de las ATSM en la región Niño 3.4 por nueve periodos

de tres meses (Estacional). Cabe recalcar que el modelo ConvLSTM solo pronóstico para seis meses de anticipación, por lo cual en las Figuras 92, 93, 94 y 95 se muestran solo 5 valores debido a que son valores estacionales (promedio de tres meses).

Para una mayor comprensión y evaluación, se dividen los modelos de pronóstico globales en tres partes: primero solo con los modelos dinámicos más representativos (Figura 93), segundo los modelos estadísticos más representativos (Figura 94) y finalmente con el promedio de los modelos dinámicos, estadísticos y promedios globales (Figura 95) con respecto a los valores observados.

Para el pronóstico estacional iniciando en enero del 2022, se observa que las habilidades de pronóstico generalmente disminuyen a medida que aumenta el tiempo de entrega (Figura 92), como se observó la mayoría de modelos pronostica a futuro condiciones neutras en pronósticos mayores al tercer mes, también se observa que el modelo NASA GMAO subestima con valores extremos (-2°C y hasta -3°C en JFM).




Figura 92: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. La línea negra continua con puntos de color cian representa las ASTM observadas y en relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente




Figura 93: Pluma de pronósticos de modelos dinámicos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

Con respecto a los modelos dinámicos más representativos (Figura 93) se observa que la mayoría de modelos tiene una proximidad a los datos observados en los tres primeros meses, posteriormente hay mucha dispersión, algunos modelos (SINTEX-F y ECMWF) tienen una tendencia creciente llegando a condiciones Neutras, mientras que el modelo NCEP CFSv2 es más moderada su tendencia creciente mostrándose en el tiempo condiciones La Niña, en el caso del modelo ConvLSTM muestra a lo largo del tiempo condiciones La Niña.

En la Figura 94, se observa la pluma de pronósticos de los modelos estadísticos más representativos y el modelo ConvLSTM con respecto a los valores observados, se muestran que los valores observados tienen una tendencia casi horizontal, mientras que el modelo ConvLSTM tiene una tendencia decreciente de la ATSM, los modelos estadísticos tienen una tendencia positiva en el tiempo por lo que muestra a futuro condiciones neutras.




Figura 94: Pluma de pronósticos de modelos estadísticos globales más representativos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

En el caso de los promedios de los modelos dinámico, estadísticos y promedio total (Figura 95) dados por IRI, se observa que estos promedios tienen una tendencia en el tiempo creciente mostrando a futuro condiciones Neutras, pero los datos observados muestran lo contrario, sigue permaneciendo en condiciones La Niña.

En general el modelo ConvLSTM para esta fecha dada muestra pronósticos siempre en condición La Niña, mientras la mayoría de modelos globales para esta fecha ya muestran condiciones Normales, el cual no es cierto.




Figura 95: Pluma de pronósticos del promedio de los modelos dinámicos, estadísticos y promedio total de modelos de ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 3.4, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

4.5.2. Discusión de pronóstico globales y el modelo ConvLSTM, en la región Niño 1+2

4.5.2.1. Año 2016/17, pronóstico estacional iniciando en noviembre (OND) del 2016

Sabiendo que el año 2017 se presentó el evento Niño Costero 2017, solo en la región Niño 1+2, se comparó el modelo ConvLSTM con otros modelos globales de pronóstico.

Los modelos utilizados para comparación y evaluación en este periodo y en esta región Niño 1+2 son: NCEP CFS v2, Agencia Meteorológica de Japón y MÉTÉO FRANCE, el cual son modelos dinámicos.

La elección de estos modelos se debe a varios factores, primero a que son los modelos más representativos a nivel global; segundo, a que en la web solo se puede encontrar datos (valores numéricos) solo de estos modelos en la región Niño 1+2, algunos modelos solo presentan gráficas (pluma de pronósticos) mas no datos numéricos; tercero, a que los modelos globales presentan poca información de datos para esta fecha de análisis (noviembre 2016); y cuarto los modelos globales en su mayoría se enfocan solo en la región Niño 3.4 mas no en Niño 1+2.

La Figura 96 muestra la pluma de pronósticos realizados por los modelos dinámicos y el modelo ConvLSTM de las ATSM en la región Niño 1+2 por nueve periodos de tres meses (Estacional). Cabe recalcar que el modelo ConvLSTM solo pronóstico para seis meses de anticipación, por lo cual en la Figura 96 se muestran solo cinco valores debido a que son valores estacionales (promedio de tres meses).

Para el pronóstico estacional iniciando en noviembre (OND) del 2016, se observa que los modelos dinámicos no representan la tendencia de los datos observados, y también en el transcurso del tiempo de pronóstico los modelos están siempre en la condición Normal ($< a - 0.5^{\circ}C$ y $> a + 0.5^{\circ}C$), sabiendo que los datos observados (Figura 96) nos muestran condición EL Niño ($> 0.5^{\circ}C$).

Con respecto al modelo ConvLSTM, en el transcurso del tiempo de pronóstico siempre muestra condición El Niño ($> 0.5^{\circ}C$) al igual que los datos observados hasta los meses de pronóstico (Figura 96). Así mismo el modelo ConvLSTM los tres primeros meses (Estacionales) tiene menor proximidad de valores con respecto a los observados, y posteriormente los tres últimos meses se aproxima más que el resto de modelos dinámicos.

En general, la capacidad de pronóstico de las ATSM en la región Niño 1+2 es menor que la del Niño 3.4 (Luo *et al.* 2008; Magnusson *et al.* 2013; Newman y Sardeshmukh 2017) tanto para los modelos globales como para el modelo ConvLSTM, pero para el caso de la región Niño 1+2 el modelo ConvLSTM mostró mejor resultado de pronóstico frente a los modelos dinámicos, observándose una mayor variabilidad de valores de las ATSM pronosticada con respecto a la observada.




Figura 96: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 1+2, iniciando en OND (meses de media móvil) del 2016. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

4.5.2.2. Año 2022, pronóstico estacional iniciando en enero (DJF) del 2022

En esta sección se pronostica las ATSM de meses de medias móviles del modelo ConvLSTM con otros modelos dinámicos globales para la región Niño 1+2. Los modelos utilizados para comparación y evaluación en este periodo son: NCEP CFS v2, Agencia Meteorológica de Japón y MÉTÉO FRANCE y ECMWF.

La Figura 97 muestra la pluma de pronósticos realizados por los modelos dinámicos y el modelo ConvLSTM de las ATSM en la región Niño 1+2 por ocho periodos de 3 meses (Estacional). Para el pronóstico estacional iniciando en enero (DJF) del 2022, se observa que los modelos dinámicos no representan la tendencia de los datos observados, y se observa en el transcurso del tiempo del pronóstico los modelos dinámicos muestran tendencia creciente a condiciones Normales de ENOS, pero se ve que los valores observados muestran condición La Niña ($< -0.5^{\circ}\text{C}$), al igual que el modelo ConvLSTM muestra a lo largo del tiempo condición La Niña, pero subestimando los valores observados.




Figura 97: Pluma de pronósticos de modelos globales ENOS y el modelo ConvLSTM con respecto a los datos observados en la región Niño 1+2, iniciando en DJF (meses de media móvil) del 2022. En relleno rojo y azul se muestra los umbrales mínimos de anomalías superiores e inferiores a 0.5°C y -0.5°C para evento El Niño y La Niña respectivamente

4.5.3. Inspección de modelos de pronósticos grillados a nivel global

Los modelos de pronósticos presentados en esta sección son modelos dinámicos como el modelo METEO FRANCE, CFSv2, SINTEX F, y el modelo ConvLSTM de manera grillada, estos serán evaluados y comparados visualmente con los datos observados dados por el producto ERSST v5 NOAA para el enero (DJF) del 2015/16 y para diciembre (NDJ) del 2016/17.

4.5.3.1. Modelos de pronósticos grillados a nivel global año 2016

Se inicia mostrando (Figura 98a) las anomalías de la TSM estacional de la media móvil de DJF (enero) del 2015/16 del producto ERSST v5 NOAA (datos observados) a nivel global. Primeramente, se observa anomalías térmicas diferentes en las cuatro regiones Niño del Pacífico Ecuatorial, en las regiones Niño 3, 4 y 3.4 se observan anomalías positivas de la TSM mayores a 3°C dando como resultado Niño extraordinario en esas regiones, en cambio, en la región Niño 1+2 las anomalías de la TSM solo están entre 1°C y 1.5°C.

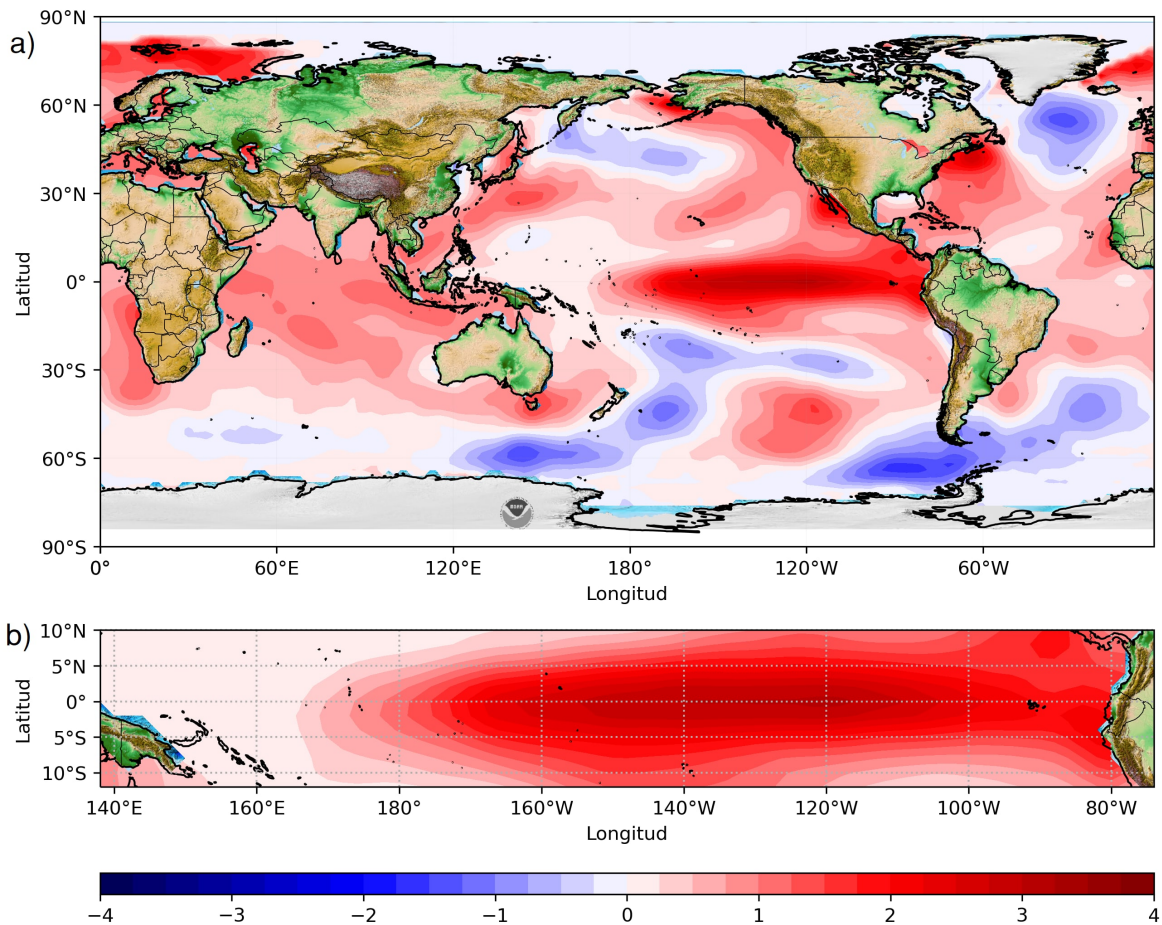


Figura 98: ATSM media móvil de enero (DJF) del 2015/16 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S–10°N y longitud 140°E – 80°W

Para el caso del modelo dinámico CFSv2 (Figura 99), se observa que en el pacífico central se presenta anomalías de la TSM positivas con valores mayores a 3°C, y en el pacífico oriental entre la latitud 0°–10°S el pronóstico presenta valores de anomalías de la TSM de 2°C a 3°C, concluyendo que en esta región 1+2 los valores pronosticados esta sobre estimado respecto a los valores observados.

Para el modelo dinámico de la Agencia Meteorológica de Japón SINTEX-F (Figura 100), se observa que en el pacífico central se presenta anomalías de la TSM positivas mayores 2°C y en el pacífico oriental anomalías de la TSM entre 1.5°C y 2°C concluyendo que en el pacífico central subestima los valores observados.

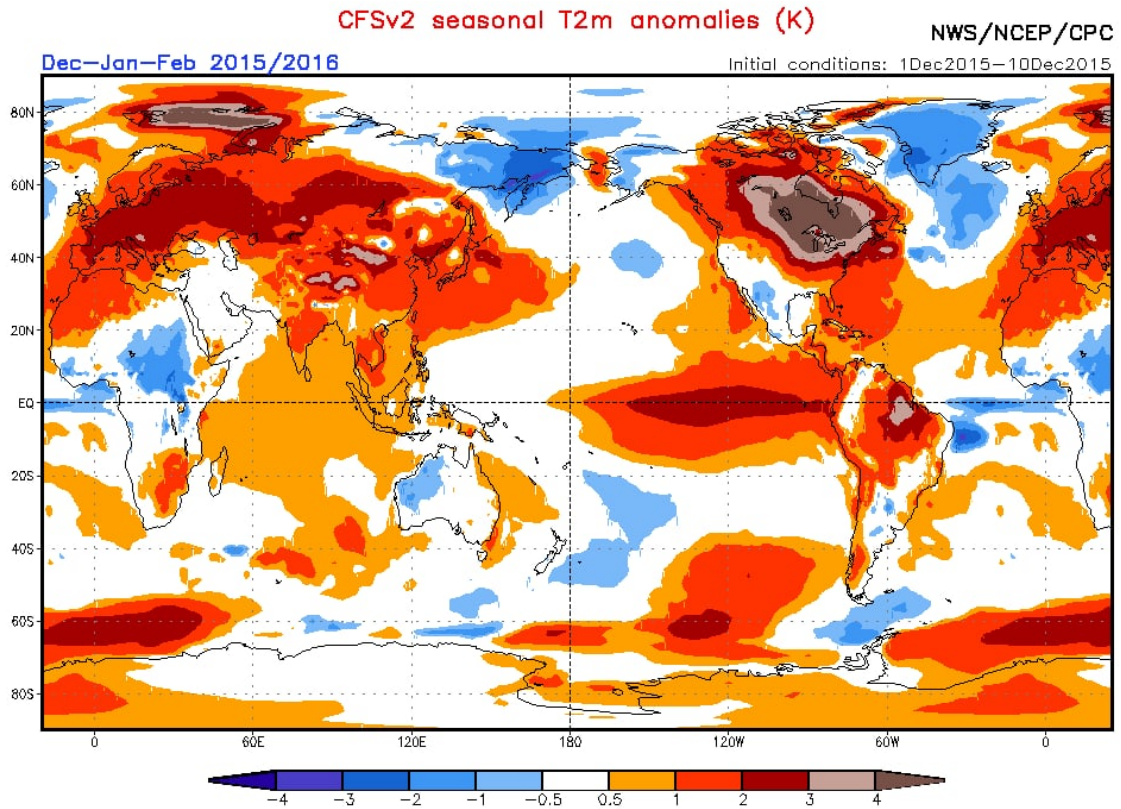


Figura 99: Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo dinámico CFSv2 a nivel global

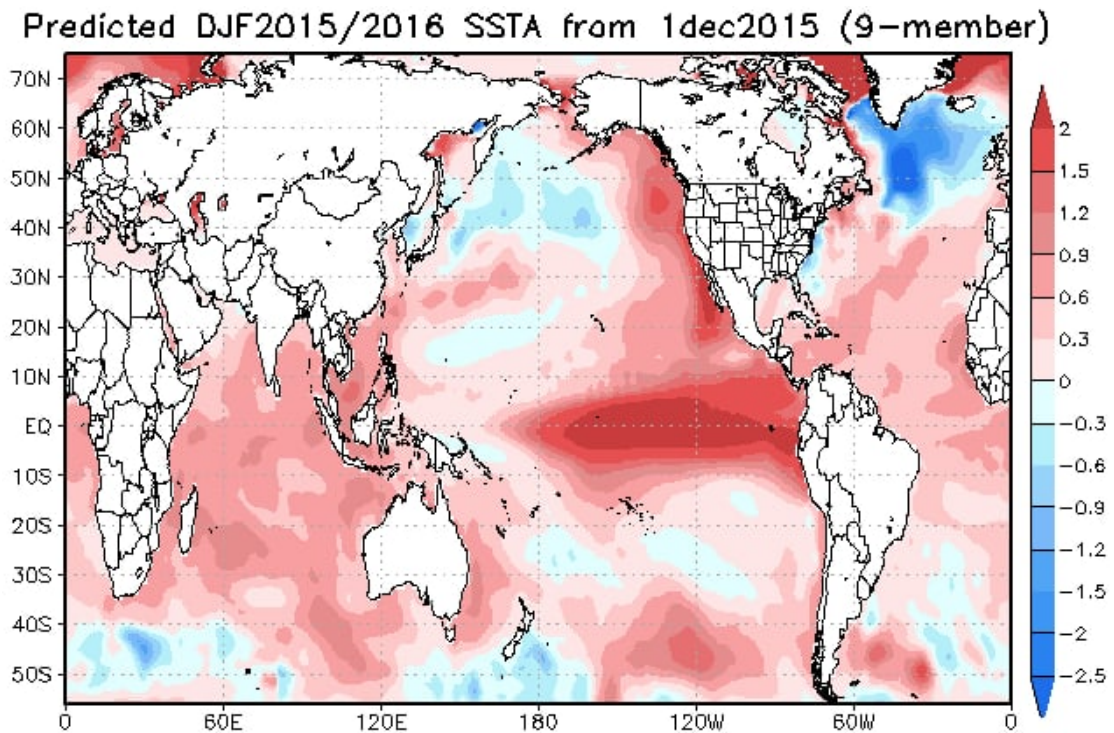


Figura 100: Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo dinámico de la Agencia Meteorológica de Japón (SINTEX-F) a nivel global

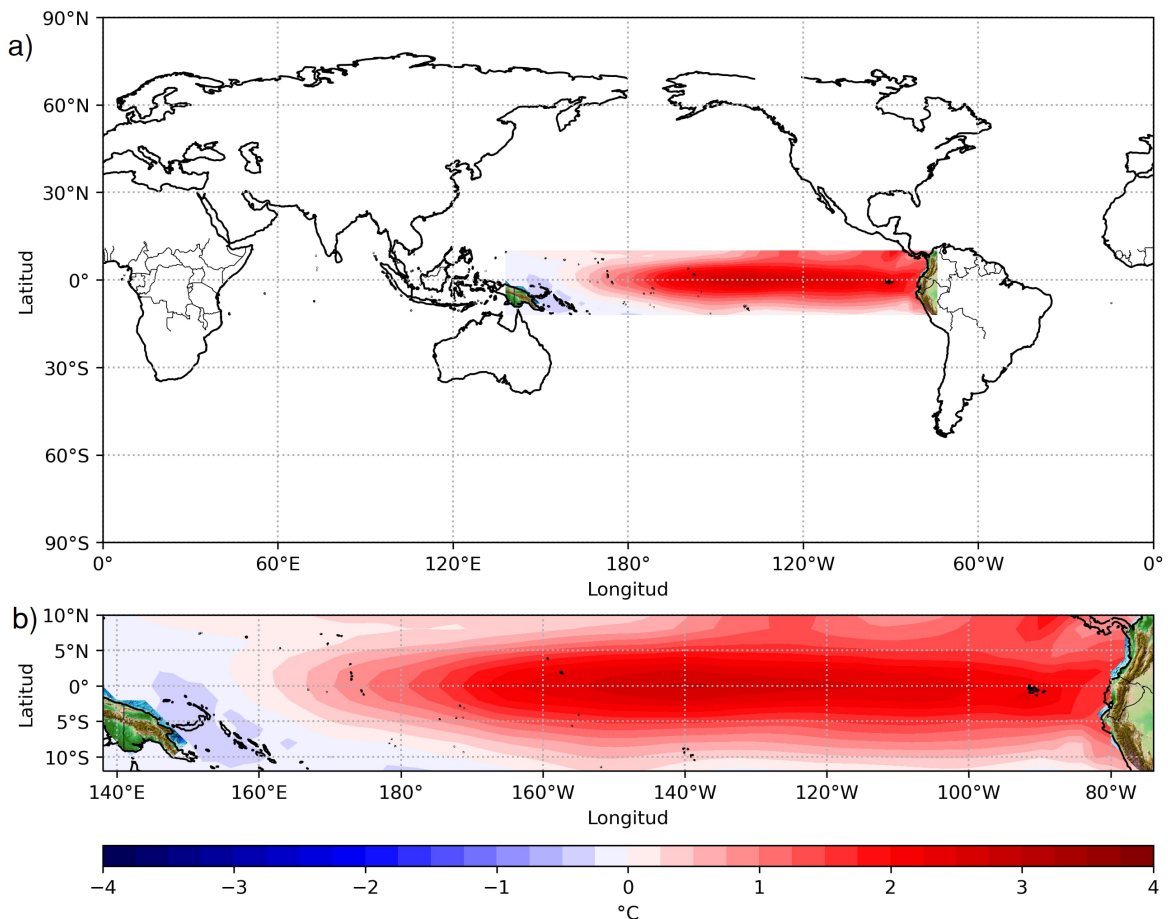


Figura 101: Pronóstico de ATSM media móvil de enero (DJF) del 2015/16 del modelo ConvLSTM a) a nivel global y b) en latitud 10°S–10°N y longitud 140°E – 80°W del océano Pacífico ecuatorial

La Figura 101 muestra el modelo ConvLSTM solo para el área de latitud 10°S–10°N y longitud 140°E – 80°W (Figuras 101a y 101b) debido a la capacidad y memoria computacional que se cuenta para esta investigación, en la Figura 101b se muestra los pronósticos de las anomalías de la TSM estacional de la media móvil de DJF (enero) del 2015/16, mostrándose en el pacífico central anomalías positivas de la TSM mayores a 2.75°C, y en el pacífico oriental anomalías positivas entre 1.75°C y 2.25°C, aproximándose a los datos observados mejor que los otros modelos.

En general todos los modelos dinámicos presentados aquí incluido el modelo ConvLSTM, muestran en el pacífico central un calentamiento de la TSM concordando con los valores observados (Figura 98), mientras que en el pacífico oriental los modelos presentan anomalías positivas excesivas a los datos observados, mientras que el modelo ConvLSTM presenta

valores más acordes y próximos a los valores observados.

4.5.3.2. Modelos de pronósticos grillados a nivel global año 2017

La Figura 102a muestra las anomalías de la TSM estacional de la media móvil de NDJ (diciembre) del 2016/17 del producto ERSST v5 NOAA (datos observados) a nivel global. Primeramente, se observan anomalías térmicas diferentes en las cuatro regiones Niño del Pacífico Ecuatorial, en las regiones Niño 3, 3.4 y 4 se observan anomalías negativas de la TSM, en cambio, en la región Niño 1+2 no se ve alterada por el enfriamiento del Pacífico Central, más bien se observa una lengua de agua superficial con anomalías positivas de la TSM en la costa de Perú con valores superiores a 1.5°C (Figura 102b).

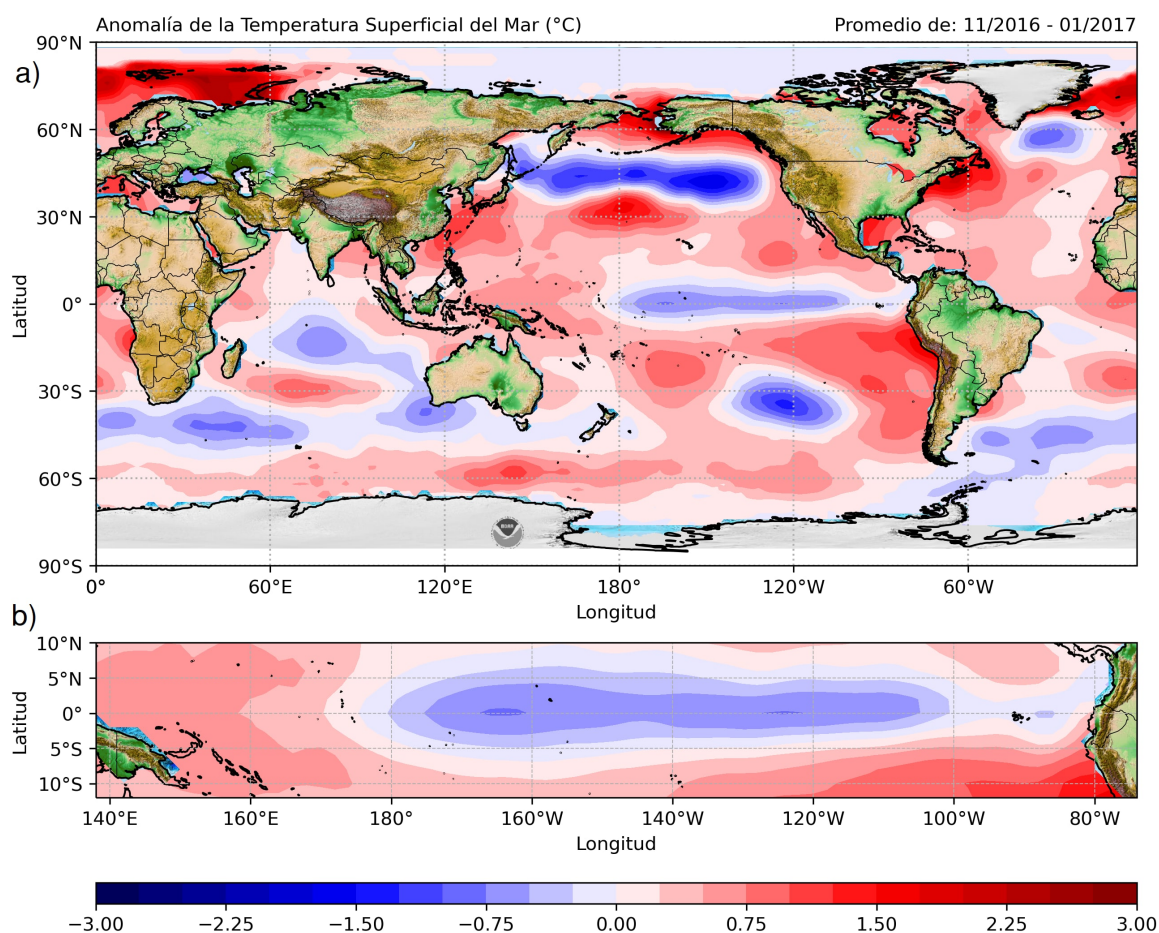


Figura 102: ATSM media móvil de diciembre (NDJ) del 2016/17 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W

Para el caso del modelo dinámico CFSv2 (Figura 103), se observa que en el pacífico central se presenta anomalías de la TSM negativas con valores entre -1.0°C a -0.5°C , y en

el pacífico oriental entre la latitud 0° – 10° S valores de anomalías de la TSM de $-1^{\circ}C$ a $-0.5^{\circ}C$ y en el pacífico oriental entre la latitud 10° S– 20° S valores de anomalías de la TSM de $0.5^{\circ}C$ a $1^{\circ}C$.

Para el modelo dinámico de la Agencia Meteorológica de Japón SINTEX-F (Figura 104), se observa que en el pacífico central se presenta anomalías de la TSM negativas con valores de $0^{\circ}C$ a $-0.6^{\circ}C$, y en el pacífico oriental entre la latitud 0° – 10° S valores de anomalías positivas de la TSM de $0^{\circ}C$ a $0.6^{\circ}C$.

En el caso del modelo dinámico METEO FRANCE (Figura 105a), se observa que en el pacífico central se presenta anomalías de la TSM negativas con valores entre $-1.0^{\circ}C$ a $-0.5^{\circ}C$, y en el pacífico oriental valores de anomalías de la TSM entre $-0.2^{\circ}C$ a $0.2^{\circ}C$, no presentando condiciones EL Niño.

La Figura 106 muestra el modelo ConvLSTM solo para el área de latitud 10° S– 10° N y longitud 140° E – 80° W (Figura 106a y 106b) debido a la capacidad y memoria computacional que se cuenta para esta investigación, en la Figura 106b se muestra los pronósticos de las anomalías de la TSM estacional de la media móvil de NDJ (diciembre) del 2016/17, mostrándose en el pacífico central anomalías negativas de la TSM entre -0.5 y $-0.75^{\circ}C$, al igual que los datos observados en la región Niño 1+2 y/o pacífico oriental se muestran anomalías de la TSM superiores a $2^{\circ}C$.

En general para todos los modelos dinámicos presentados aquí incluido el modelo ConvLSTM, muestran en el pacífico central un debilitamiento de las condiciones de la TSM concordando con los valores observados (Figura 102), mientras que en el pacífico oriental los modelos METEO FRANCE, y CFSv2 presentan anomalías negativas, el cual no tiene relación con los datos observados, mientras que el modelo SINTEX-F si presenta anomalías positivas de la TSM pero con valores que no llegan a condiciones El Niño (Figura 104), y el modelo ConvLSTM presenta anomalías positivas de la TSM (Figura 106) con valores que si presenta condiciones El Niño concordando con los datos observados.

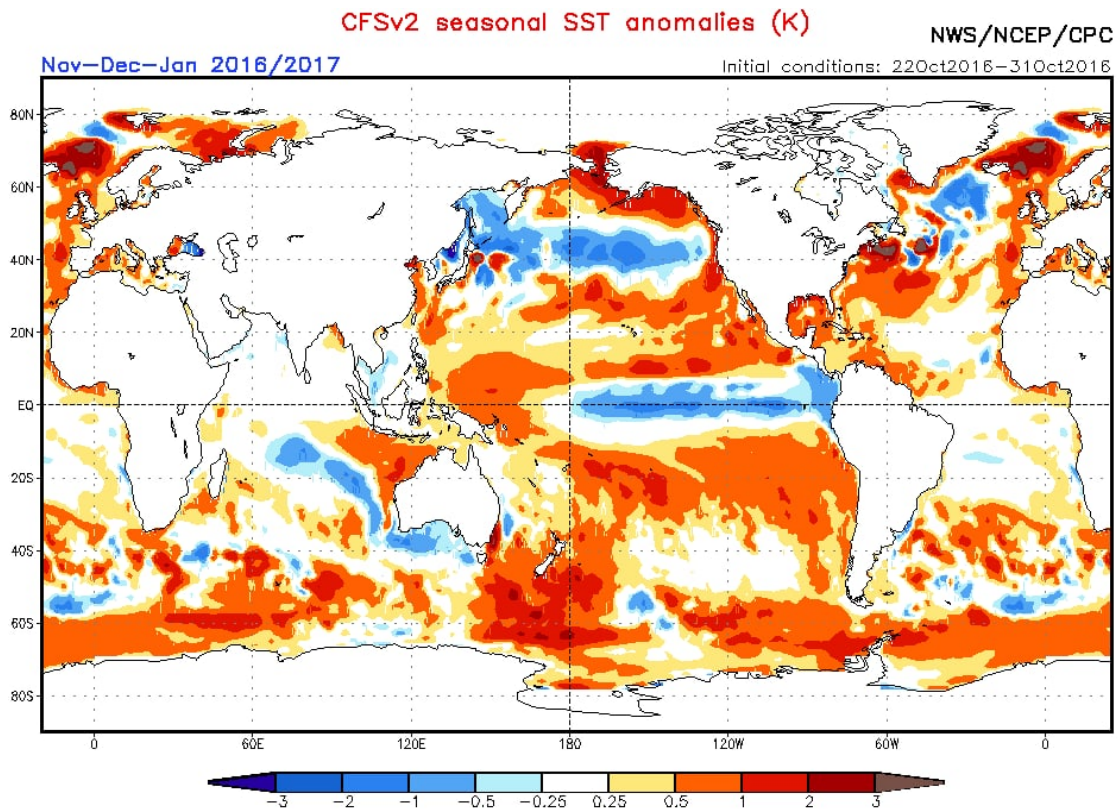


Figura 103: Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico CFSv2 a nivel global

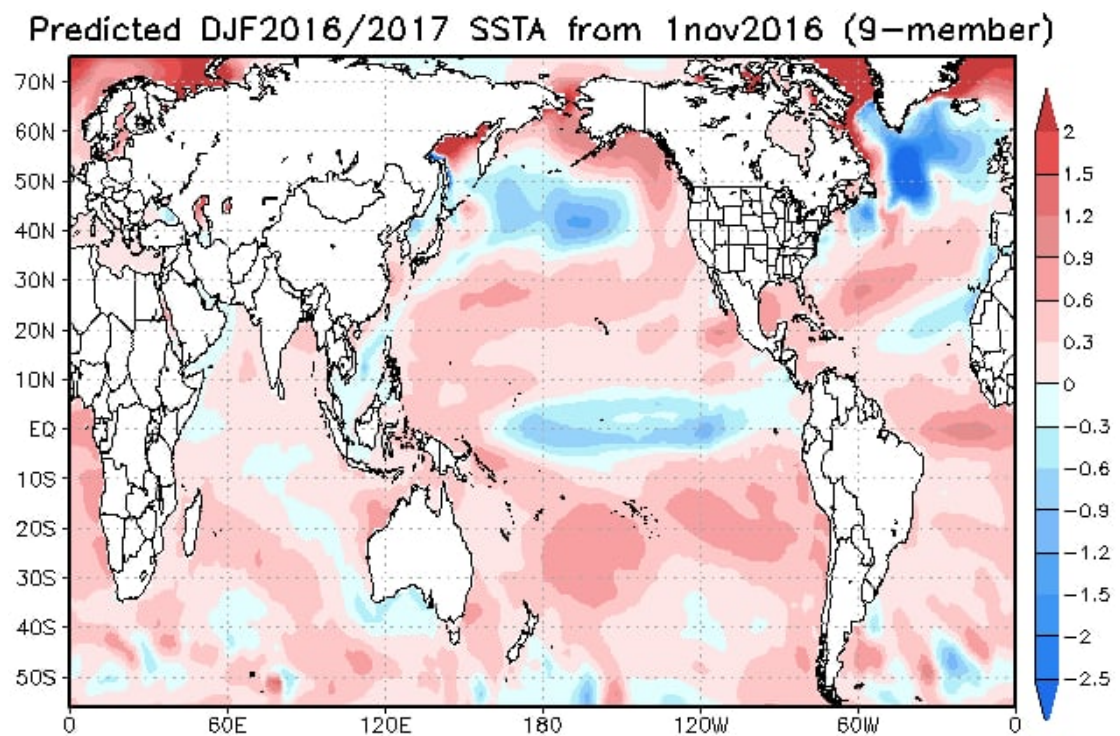


Figura 104: Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico de la Agencia Meteorológica de Japón (SINTEX-F) a nivel global

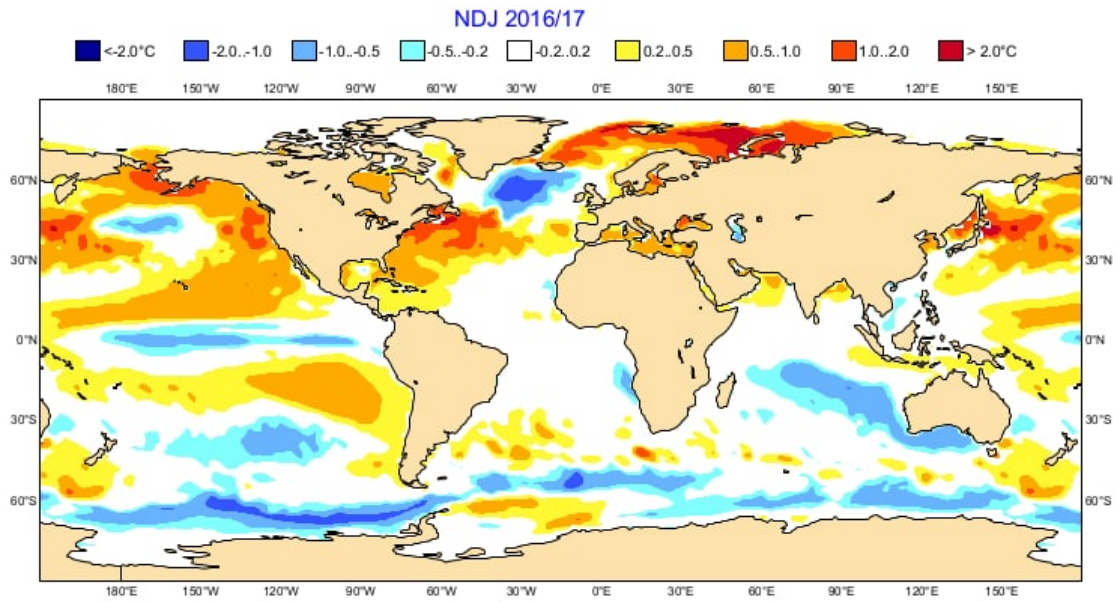


Figura 105: Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo dinámico METEO FRANCE a nivel global

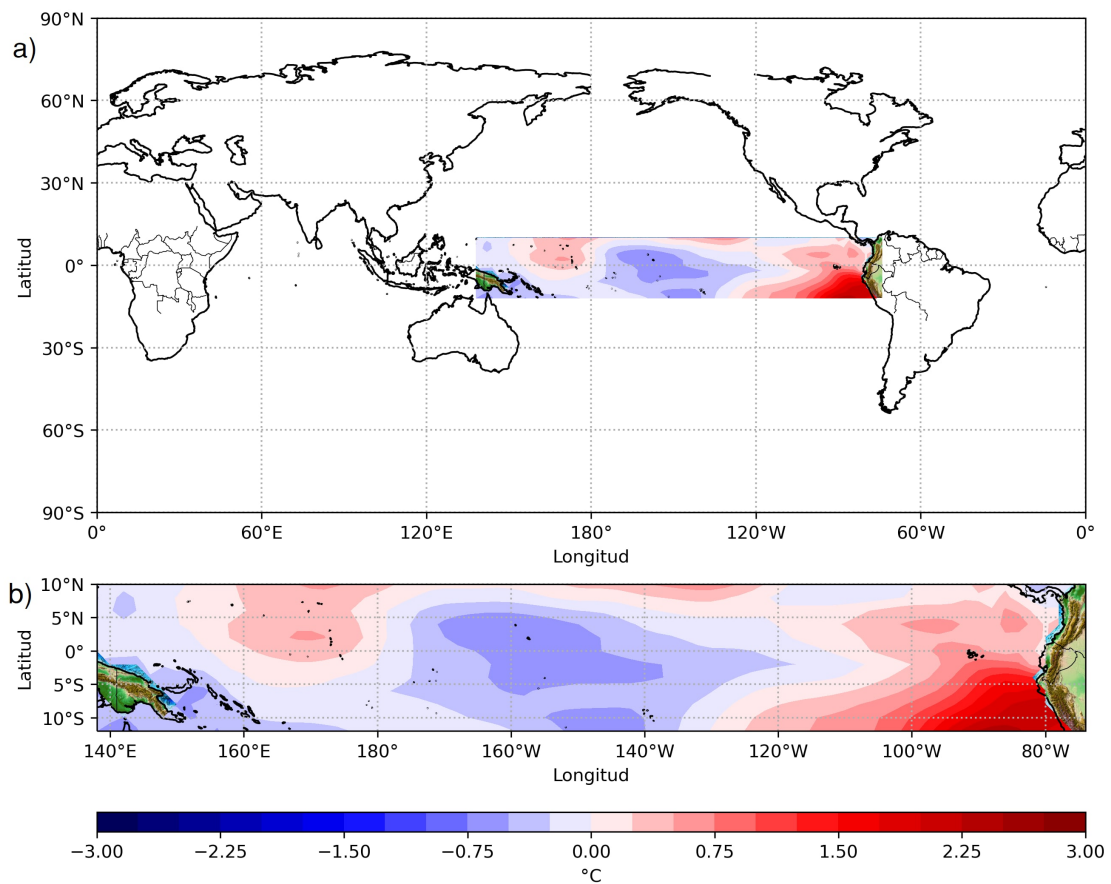


Figura 106: Pronóstico de ATSM media móvil de diciembre (NDJ) del 2016/17 del modelo ConvLSTM a) a nivel global y b) latitud 10°S–10°N y longitud 140°E – 80°W del océano pacífico

4.5.3.3. Modelos de pronósticos grillados a nivel global año 2022

La Figura 107a muestra las anomalías de la TSM estacional de la media móvil de JFM (febrero) del 2022 del producto ERSST v5 NOAA (datos observados) a nivel global. Primeramente, se observa anomalías de la TSM negativas en las cuatro regiones Niño del Pacífico Ecuatorial, con valores entre -0.5°C y -1.5°C (Figura 107b).

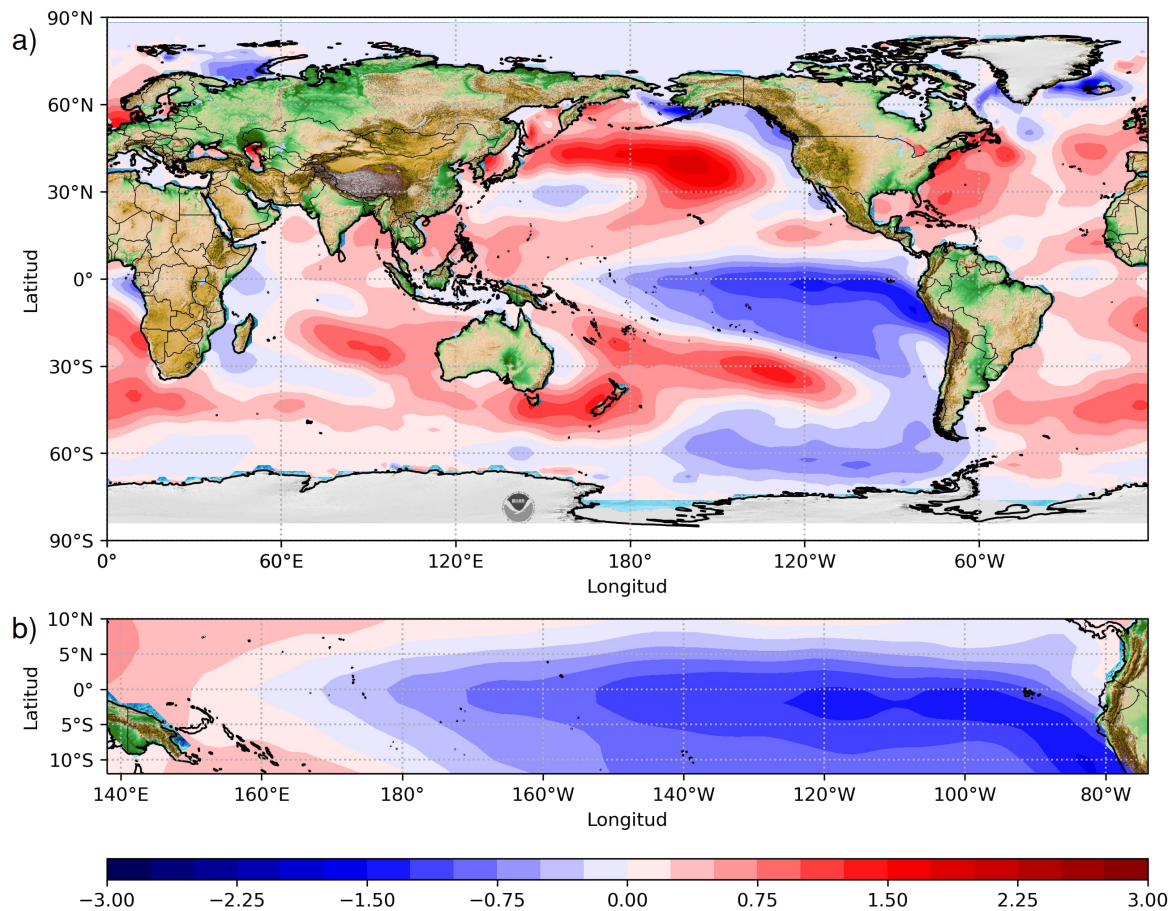


Figura 107: ATSM media móvil de febrero (JFM) del 2022 de datos observados a) a nivel global y b) del océano Pacífico ecuatorial de latitud 10°S–10°N y longitud 140°E – 80°W

Para el caso del modelo dinámico CFSv2 (Figura 108), se observa que en el pacífico central y oriental se presenta anomalías de la TSM negativas con valores entre -0.5°C a -2°C .

El modelo dinámico METEO FRANCE (Figura 109), se observa que en el pacífico central se presenta anomalías de la TSM negativas con valores entre -1°C a -2°C , y en el pacífico oriental valores de anomalías de la TSM entre -0.5°C a -0.2°C .

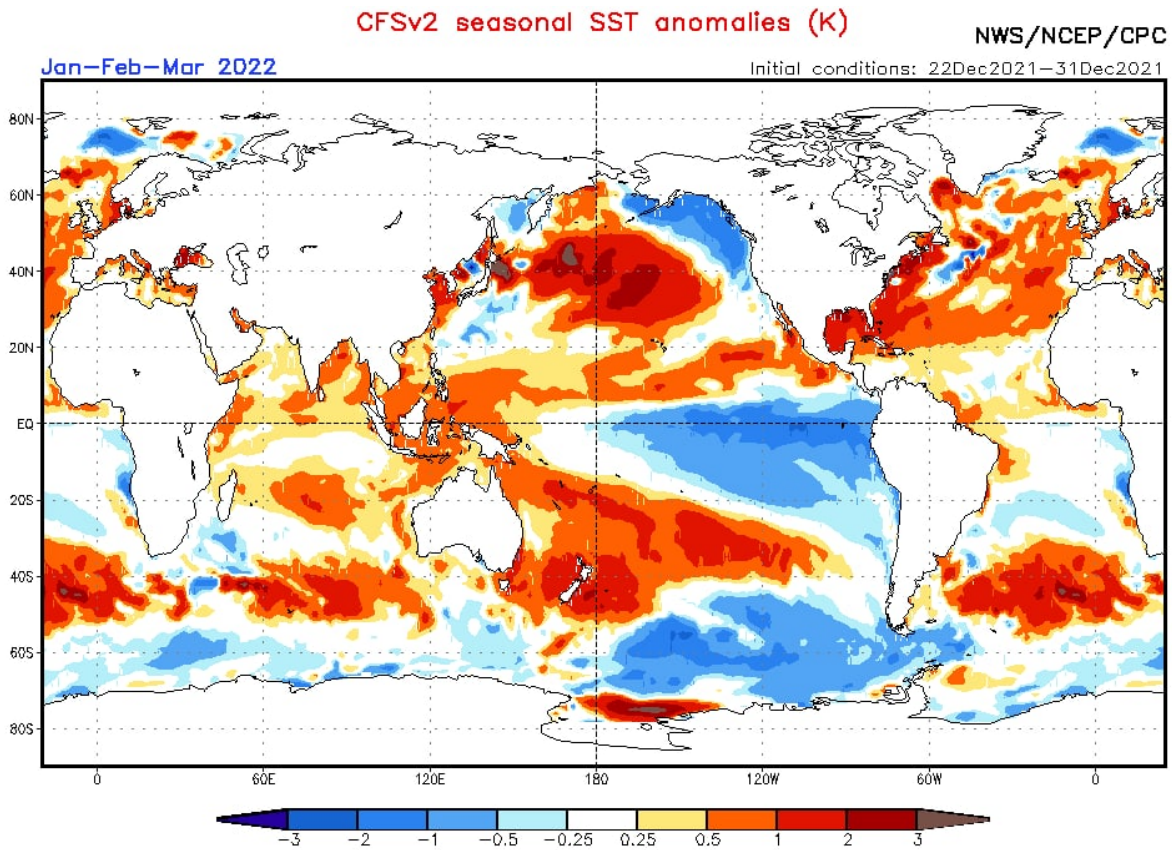


Figura 108: Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo dinámico CFSv2 a nivel global

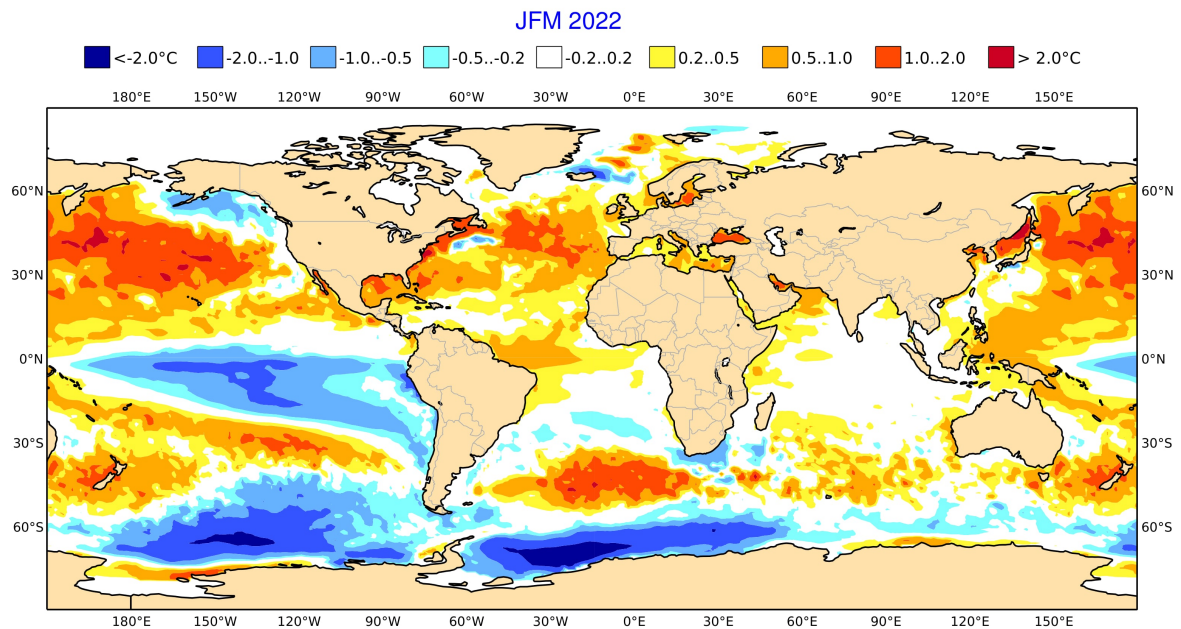


Figura 109: Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo dinámico METEO FRANCE a nivel global

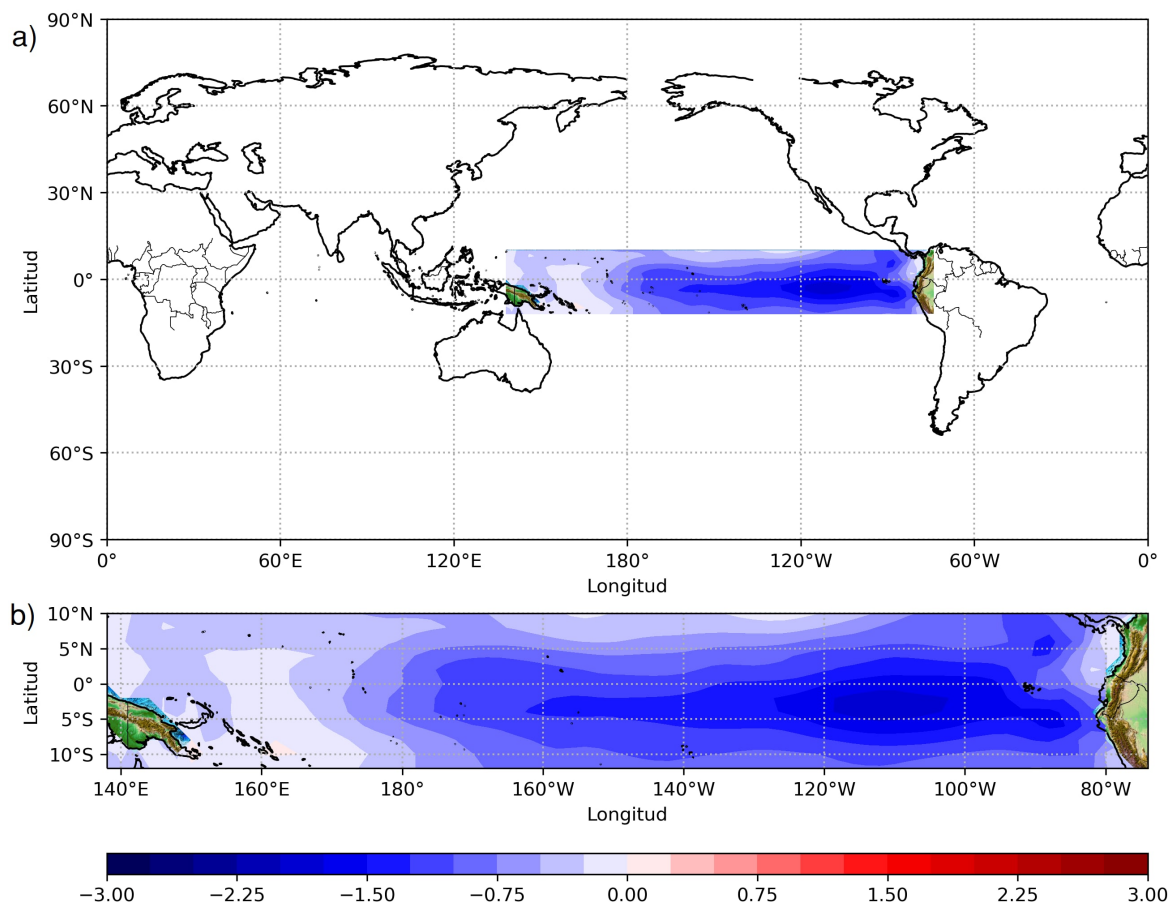


Figura 110: Pronóstico de ATSM media móvil de febrero (JFM) del 2022 del modelo ConvLSTM a) a nivel global y b) latitud 10°S–10°N y longitud 140°E – 80°W del océano pacífico

La Figura 110 muestra el modelo ConvLSTM solo para el área de latitud 10°S–10°N y longitud 140°E – 80°W (Figuras 110a y 110b) debido a la capacidad y memoria computacional que se cuenta para esta investigación, en la Figura 110b se muestra los pronósticos de las anomalías de la TSM estacional de la media móvil de JFM (febrero) del 2022 observando en todas las regiones Niño valores entre $-0.5^{\circ}C$ y $-2.0^{\circ}C$.

En general para el año 2022 todos los modelos incluido el modelo ConvLSTM, presentan condiciones La Niña para esta fecha de pronóstico.

4.6. DISCUSIÓN DE RESULTADOS

Al revisar estudios científicos previos (L'Heureux *et al.* 2017; Nooteboom *et al.* 2018; Tang *et al.* 2018; Pal *et al.* 2020; Yan *et al.* 2020), se observa que la comprensión de ENOS ha

logrado grandes éxitos y continúa fortaleciéndose. No solo se ha construido muchos modelos con una variedad de grados de complejidad, sino también pronosticar ENOS de manera efectiva en algunos años (por ejemplo, el pronóstico de El Niño 2015/16). Sin embargo, los estudios de ENOS aún enfrentan muchos problemas y desafíos, aún existen grandes sesgos e incertidumbres al hacer pronósticos utilizando los enfoques tradicionales, incluidos los métodos estadísticos y dinámicos basados en ecuaciones del océano y la atmósfera.

Probablemente, lo que hace que el pronóstico de ENOS sea tan desafiante, es que cada evento de ENOS (sea Niño o Niña) son muy diferentes (McPhaden 2018), corroborado también en esta investigación en la sección 4.1 (exploración de datos de eventos ENOS). Además, uno de los obstáculos críticos que encuentran la mayoría de los modelos del aprendizaje profundo (DL, en sus siglas en inglés) para pronosticar fenómenos climáticos como ENOS es la falta de disponibilidad de datos de observación lo suficientemente largas (Nooteboom *et al.* 2018; Tang *et al.* 2018; Pal *et al.* 2020; Yan *et al.* 2020). Por ejemplo, es sabido que desde 1980 ha habido solo 3 o 4 eventos importantes de El Niño (y un número similar de eventos importantes de La Niña). Por lo cual en esta investigación se usa la mayor cantidad de datos existente de la TSM, por lo cual se usó datos de la NOAA desde 1854 hasta el 2022.

Los avances científicos recientes en la inteligencia artificial y específicamente en el DL nos brindan la oportunidad de usar estas técnicas para pronosticar la TSM espacio temporal en el Pacífico ecuatorial. En esta investigación se hizo un intento exitoso de utilizar técnicas de DL usando el modelo ConvLSTM, con el fin de proporcionar la evolución de ENOS espacio temporal y mejorar la habilidad de pronóstico de ENOS también espacio temporal. Específicamente, en función de mapas grillados de la TSM y ATSM en el pacífico ecuatorial (latitud 10°S–10°N y longitud 140°E–80°W).

En comparación con modelos anteriores de pronóstico de ENOS basados en el aprendizaje profundo, aprendizaje automático y RNA (Nooteboom *et al.* 2018; Pal *et al.* 2020; Yan *et al.* 2020) que descubrieron patrones y tendencias de ENOS en función de series temporales (Yan *et al.* 2020), como también existen estudios previos que mostraron buenas habilidades con modelos estadísticos, desarrollado para el pronóstico de ENOS de mediano y largo

plazo (Ludescher *et al.* 2013; Petrova *et al.* 2020), pero la mayoría de estos estudios lo hacen con series temporales y se enfocan en la región Niño 3.4 (índice Niño 3.4 y ONI), la propuesta ConvLSTM comprende el comportamiento espacio temporal de la TSM y ATSM en el pacífico ecuatorial que incluye la región Niño 3.4 y Niño 1+2.

El modelo ConvLSTM, respecto del pronóstico de ENOS, proporcionó varios resultados interesantes. De estos resultados se discuten los siguientes.

Primero, los resultados de la TSM espacio temporal de valores pronosticados con respecto a los valores observados, se menciona que el modelo ConvLSTM en todos los años de pronóstico (2015/16, 2017 y 2022), dio resultados aceptables en seis meses de pronóstico dados en las Tablas 15, 18, 21 y 24 (Lewis 1982; Jamieson *et al.* 1991; Chen *et al.* 2003; Li *et al.* 2013), pero con resultados estadísticos de excelente en los tres primeros meses (Figuras 54, 55, 59, 60 y 75 para el área de estudio del pacífico ecuatorial y la región Niño 3.4 y para Figuras 56, 71 y 76 de la región Niño 1+2).

Segundo, se comparó los resultados obtenidos de pronósticos con series de tiempo de los índices de la ATSM de la región Niño 3.4 y Niño 1+2 (Figuras 64, 69 y 79) con 6 meses de anticipación en los años 2015/16, 2017 y 2022, dando como resultado en general de esos años, que los tres primeros meses de pronósticos se aproximan a los valores observados en la región Niño 3.4 y Niño 1+2, a excepción del 2017 en la región Niño 1+2 en los dos primeros meses.

Tercero, en cuestión, a la comparación con modelos ya sean estadísticos y dinámicos, en función de índices climáticos (series de tiempo de la ATSM de la región Niño 3.4 y Niño 1+2 de la media móvil de tres meses) de la ATSM en la región Niño 3.4 y Niño 1+2, se afirma lo siguiente:

De los resultados obtenidos en la sección 4.5.1 para la región Niño 3.4, se observó que el modelo ConvLSTM, muestra pronósticos que superan a los modelos estadísticos (por ejemplo, NOAA/CDC Linear Inverse y NCEP/CPC Can Cor Anal) para El Niño 2015/16 y año 2017, por tener una mayor aproximación a los datos reales. Así mismo, el modelo

ConvLSTM da mejores resultados que algunos modelos dinámicos, por ejemplo, para el Año 2015/16 resulta mejor que NCEP CFS v2, JMA y ECMWF, y para La Niña 2022 resulta mejor que SINTEX-F y ECMWF.

En el caso del evento Niño costero 2017 en la región Niño 1+2, el modelo ConvLSTM si pronostica el evento Niño Costero 2017, pero sobrestima los valores reales (Figura 96). En el caso de los modelos dinámicos, ninguno pronostica el evento Niño costero 2017 mostrando condiciones neutras en la región Niño 1+2.

Cuarto, en cuestión, a la comparación de mapas grillados de la ATSM en el pacífico ecuatorial de modelos dinámicos, se afirma que, si bien los modelos dinámicos son los que proporcionan la información de mapas grillados, mas no los estadísticos, el modelo ConvLSTM también proporciona mapas grillados espacio temporales de la TSM como resultado, por lo tanto, se afirma que con respecto a los datos observados grillados, tanto los modelos dinámicos (NCEP CFS v2, SINTEX-F y ECMWF) como el ConvLSTM se aproximan a estos valores observados (para el año 2015/2016, 2017 y 2022), pero para el año 2017 específicamente en la región Niño 1+2 los modelos dinámicos no representan la evolución del Niño en esa región, más si lo hizo el modelo ConvLSTM.

Por otro lado, el aprendizaje profundo, tiene la ventaja de pronóstico rápido (recurso computacional) y económico sobre nuevos datos después de haber sido entrenado. La velocidad y la economía ofrecen una clara ventaja sobre muchos modelos físicos (dinámicos) en ciencias de la Tierra (océano y la atmósfera). Además, los avances recientes en las técnicas de aprendizaje profundo, y el aprendizaje automático aplicados a las ciencias de la tierra, están arrojando resultados muy prometedores en la estimación de la convección atmosférica, la TSM y por ende de ENOS (Maskey *et al.* 2020).

Por lo tanto, como estudio futuro, se tiene la intención de desarrollar una arquitectura de redes neuronales de aprendizaje profundo basada en leyes físicas de ENOS y su aplicabilidad segura para pronosticar fenómenos climáticos y océano atmosféricos. Sobre todo, desarrollar una arquitectura que pueda explicar cuantitativamente y físicamente ENOS para así aumentar la confiabilidad del uso de técnicas de aprendizaje profundo.

V. CONCLUSIONES

En las regiones Niño del Pacífico Ecuatorial se ha evidenciado y documentado la ocurrencia de eventos ENOS cada vez más recurrentes en las últimas décadas, con impactos severos en todo el mundo y principalmente en Perú. Estos escenarios de variabilidad climática han generado problemas en los ámbitos sociales ambientales y económicos.

El desarrollo de esta investigación se constituyó en cuatro objetivos específicos, obteniendo las siguientes conclusiones:

Proponer un modelo de red neuronal profunda, que integra la memoria convolucional a corto y largo plazo (ConvLSTM).

- Se propone el modelo ConvLSTM que es una red neuronal profunda para pronosticar eventos ENOS espacio temporales, a diferencia de algunos modelos dinámicos y estadísticos de pronóstico de ENOS, que solo proponen pronosticar ENOS en función de series de tiempo, el modelo además de lo anterior puede pronosticar eventos ENOS grillados (ubicado geográficamente en el océano Pacífico ecuatorial de latitud 10°S–10°N y longitud 140°E– 80°W) simultáneamente. Todo este proceso fue elaborado en el lenguaje de programación Python, elegida por su rápida habilidad de proceso computacional, acompañado e integrado también de la API de inteligencia artificial de Tensorflow y Keras perteneciente a Google.

Verificar el modelo de red neuronal profunda para pronósticos El Niño extraordinario.

- Se entrenó y validó los datos de ENOS con años Niño Extraordinario en distintas etapas, como es el caso del Niño 1982/83 (entrenamiento) y Niño 1997/98 (validación) y se pronosticó lo observado con seis meses de anticipación para meses de mayor evolución del Niño (octubre a marzo) en el océano Pacífico ecuatorial de latitud 10°S–10°N y longitud 140°E– 80°W. Concluyendo que en esta etapa se obtuvieron

muy buenos resultados tanto espacial como temporal, comparado y medido a partir de métricas estadísticas de los datos observados y datos pronosticados a lo largo de seis meses dados.

Calcular y pronosticar anomalías de la temperatura superficial del mar de las regiones Niño 3.4 y Niño 1+2, mediante la red neuronal profunda.

- De los resultados obtenidos de los pronósticos ENOS del año 2015/16 con seis meses de anticipación, se observa en el océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W , que dan muy buenos resultados las métricas estadísticas de los tres primeros meses, aminorándose los resultados de las métricas estadísticas a medida que avanza los meses de pronóstico. En cuestión solo a regiones Niño específicas, como la región Niño 3.4 los resultados fueron muy buenos en todos los seis meses pronosticados, mostrando las métricas estadísticas próximos a cero. En el caso de la región Niño 1+2 los resultados muestran buenas métricas estadísticas en los cuatro primeros meses pronosticados.
- Para el pronóstico del Niño costero 2017 iniciado en noviembre del 2016 y para seis meses de anticipación, se observa en el océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W , que el modelo representa mejor el pronóstico en la región Niño 3.4, con valores de pronóstico más próximas a los observados. En el caso de solo regiones Niño específicas, como la región Niño 1+2 los resultados indican que el modelo ConvLSTM pronosticó el evento Niño, pero con valores sobreestimados en los dos primeros meses y posteriormente los últimos meses se aproxima más a los valores observados. En el caso de la región Niño 3.4 los resultados muestran muy buenas métricas estadísticas en los tres primeros meses pronosticados, teniendo en cuenta que para este año en esta región 3.4 está en fase neutra (Condición Normal).
- Para el pronóstico de la Niña 2022 iniciado en enero 2022 y para seis meses de anticipación, se observa en el océano Pacífico ecuatorial de latitud 10°S – 10°N y longitud 140°E – 80°W , que el modelo dan muy buenos resultados de las métricas estadísticas de los tres primeros meses, aminorándose los resultados de las métricas estadísticas a medida que avanza los meses de pronóstico. En cuestión a las regiones Niño, tanto en la región Niño 3.4 y Niño 1+2 los resultados fueron muy buenos en todos los seis meses pronosticados, mostrando las métricas estadísticas próximos a cero.

- Se demuestra que el modelo ConvLSTM, además de pronosticar eventos ENOS extremos (Niña o Niño), también modelo eventos ENOS neutros, como fue el caso de la región Niño 3.4 del año 2016/17. Así mismo, se concluye que a medida que el pronóstico se incrementa en meses se va perdiendo las correlaciones de las métricas estadísticas mostrando valores más altos (no correlacionados).
- De los resultados obtenidos se concluye que hay un mejor pronóstico en la región Niño 3.4 que en Niño 1+2, esto se debería y es sabido que el modelo ConvLSTM por la propia arquitectura de red neuronal profunda pronostica con la ayuda de sus vecinos próximos (celdas y/o cuadrículas vecinas), en el caso de la región 1+2 que geográficamente está ubicado en pacífico oriental el cual interactúa con América del sur donde no hay datos (por ser continente), hace que el modelo pierda su habilidad de pronóstico ya que no hay interacción con vecinos próximos para pronosticar adecuadamente.

Comparar y evaluar el modelo de red neuronal profunda con modelos dinámicos y estadísticos globales.

- El modelo ConvLSTM en todos los pronósticos elaborados en medias móviles de tres meses (Estacional), siempre tiene la tendencia (Creciente o decreciente) de los datos observados, por lo cual pronostica y representa la evolución (o decaimiento) de la TSM, tal igual que los observados. Para el evento Niño 2015/16, el pronóstico dado por el modelo ConvLSTM fue representado óptimamente en su fase inicial de evolución del Niño 2015/16 (de julio a diciembre del 2015) como también en su valor máximo y su decaimiento de la TSM del evento Niño 2015/16 (de enero a junio del 2016), se observa también que represento mejor los pronósticos que los modelos estadísticos y que algunos modelos dinámicos a lo largo del tiempo.
- Se observa y demuestra que para el Niño 2017 en la región Niño 1+2, el modelo ConvLSTM, represento mejor los resultados de pronóstico que todos los modelos globales existentes, evidenciando que estos modelos globales nunca pronosticaron el evento Niño Costero 2017, por el contrario, el modelo ConvLSTM si pronosticó las ATSM en condición El Niño del 2017.
- Para la Niña 2022, tanto en la región Niño 3.4 y Niño 1+2, el modelo ConvLSTM representa la tendencia decreciente de la Niña al igual que los datos observados, en

cuestión a los modelos globales, muestran tendencias crecientes con pronósticos de condiciones normales desde el cuarto mes de pronóstico. Por lo que se afirma que el modelo ConvLSTM pronostica las condiciones La Niña 2022.

- En cuestión a los modelos dinámicos grillados se observa que para el año 2016 los modelos dinámicos grillados y el modelo ConvLSTM presentan anomalías positivas de la TSM dado condiciones el Niño y se aproximan a los datos grillados observados. Para el año 2017 los modelos dinámicos grillados y el modelo ConvLSTM muestran en el pacífico central un debilitamiento de las condiciones de la TSM tal y como se da con valores observados, pero para el pacífico oriental los modelos METEO FRANCE, y CFSv2 presentan anomalías negativas de la TSM, el cual no tiene relación con los datos observados (presentan ATSM positivas), en contraste, el modelo SINTEX-F si presenta anomalías positivas de la TSM pero con valores que no llegan a condiciones El Niño, el modelo propuesto ConvLSTM presenta anomalías positivas de la TSM con valores que si presenta condiciones El Niño concordando con los datos observados grillados. Para el año 2022 evento La Niña, los modelos dinámicos grillados y el modelo ConvLSTM muestran ATSM negativas en el pacífico central y oriental al igual que los datos observados.

Por lo tanto, se resume de esta investigación:

- En primer lugar, que el modelo ConvLSTM, representa mejor el pronóstico que los modelos Estadísticos a lo largo del tiempo, esto fue visto en todos los periodos elegidos de pronósticos que se hizo, pero el modelo ConvLSTM todavía no supera a algunos modelos dinámicos globales.
- En segundo lugar, se concluye que, en todos los años y meses de inicio elegido para pronósticos, se observa que las habilidades de pronóstico generalmente disminuyen a medida que aumenta el tiempo de entrega tanto para el modelo ConvLSTM y los modelos globales.
- En tercer lugar, se concluye que los pronósticos hechos en algunas épocas (meses) del año generalmente tienen mayor destreza que los pronósticos hechos en otras épocas del año, ya que se observó que generalmente los eventos de El Niño y La Niña tienden a desarrollarse durante el período abril - junio y tienden a alcanzar su fuerza máxima durante octubre – febrero, corroborando lo que ya mencionó la NOAA.

- Y por último, se demostró que el uso de las redes neuronales profundas, es una solución muy útil y con poca demanda computacional con respecto a otros modelos dinámicos para pronosticar eventos ENOS.

VI. RECOMENDACIONES

Los resultados obtenidos en esta investigación proponen la ampliación, profundización y nuevas perspectivas de investigación respecto a la variabilidad climática del océano – atmósfera y ENOS. A continuación, se detallan las recomendaciones, los alcances de la investigación y las futuras perspectivas:

- Dependiendo de la capacidad computacional con la que se cuenta, se debería ampliar el área de estudio con el modelo ConvLSTM, de modo que permita relacionar mejor la mayor cantidad de variables de la TSM en el océano pacífico y por consiguiente mejorar el pronóstico de ENOS.
- Al modelo ConvLSTM, se tiene que integrar mayor información física que representa el comportamiento océano – atmósfera espacio temporal de manera más integral, como por ejemplo los vientos a gran escala a distintos niveles, presión atmosférica, precipitaciones, etc; para un mejor pronóstico y aproximación a los datos observados.
- A medida que la comprensión de ENOS se va ampliando también surge la necesidad de mayor cantidad y calidad de datos de observación y reanálisis, de registros de datos paleo climáticos y una mejor comprensión de la interacción del océano y la atmósfera, esto ayudaría a explorar más a fondo los precursores de ENOS y mejoraría la comprensión de su previsibilidad.
- Para trabajos futuros se debe considerar a los modelos de pronóstico de ENOS características no lineales adicionales, como el calentamiento global y las actividades humanas, el cual será imprescindible y más confiables los pronósticos de ENOS en un clima cambiante.
- Así mismo se debería enfocar más en regiones específicas del Pacífico Tropical que tienen consecuencias (ya se lluvias extremas o sequías) en diferentes zonas del Perú

(Costa sur, sierra norte centro sur y selva), pero con la inclusión de instrumentos (por ejemplo: boyas, flotadores ARGO) en el litoral peruano para su respectivo pronóstico a futuro.

VII. REFERENCIAS BIBLIOGRÁFICAS

- Akouaydi, H., Njah, S., Ouarda, W., Samet, A., Dhieb, T., Zaied, M. y Alimi, A. M. 2019. Neural architecture based on fuzzy perceptual representation for online multilingual handwriting recognition. *arXiv preprint arXiv:1908.00634*.
- Ali, M., Prasad, R., Xiang, Y. y Deo, R. C. 2020. Near real-time significant wave height forecasting with hybridized multiple linear regression algorithms. *Renewable and Sustainable Energy Reviews*, 132:110003.
- Armstrong, J. S. y Collopy, F. 1992. Error measures for generalizing about forecasting methods: Empirical comparisons. *International journal of forecasting*, 8(1):69-80.
- Barnston, A. G. 1997. Documentation of a highly ENSO - related SST region in the equatorial Pacific. *Atmosphere-ocean*, 35:367-383.
- 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.
- Bauer, P., Thorpe, A. y Brunet, G. 2015. The quiet revolution of numerical weather prediction. *Nature*, 525(7567):47-55.
- Bjerknes, J. 1969. Monthly weather review atmospheric teleconnections. *Mon Weather Rev*, 97:163-172.
- Broni-Bedaiko, C., Katsriku, F. A., Unemi, T., Atsumi, M., Abdulai, J.-D., Shinomiya, N. y Owusu, E. 2019. El Niño-Southern Oscillation forecasting using complex networks analysis of LSTM neural networks. *Artificial Life and Robotics*, 24(4):445-451.

- Cane, M. y Zebiak, S. 1989. Dynamical forecasts of the 1986–1987 ENSO with a coupled model. *Proceedings of the Thirteenth Annual Climate Diagnostics Workshop, Oct, 31*.
- Capotondi, A., Wittenberg, A. T., Newman, M., Di Lorenzo, E., Yu, J.-Y., Braconnot, P., Cole, J., Dewitte, B., Giese, B., Guilyardi, E. *et al.* 2015. Understanding ENSO diversity. *Bulletin of the American Meteorological Society*, 96(6):921-938.
- Carranza, L. 1891. Contra-corriente marítima observada en Paita y Pacasmayo. *Boletín de La Sociedad Geográfica de Lima*. 9, 344:346.
- Carrillo, C. 1892. Hidrografía oceánica. *Bol. Soc. Geogr. Lima*, 1:72-111.
- Chen, R., Bloomfield, P. y Fu, J. S. 2003. An evaluation of alternative forecasting methods to recreation visitation. *Journal of Leisure Research*, 35(4):441-454.
- Chollet, F. 2015. *Keras Published on GitHub*. <https://github.com/fchollet/keras>
- Collins, M., An, S.-I., Cai, W., Ganachaud, A., Guilyardi, E., Jin, F.-F., Jochum, M., Lengaigne, M., Power, S. y Timmermann, A. 2010. The impact of global warming on the tropical Pacific Ocean and El Niño. *Nature Geoscience*, 3(6):391-397.
- Daubechies, I. 1990. The wavelet transform, time - frequency localization and signal analysis. *IEEE transactions on information theory*, 36(5):961-1005.
- Davey, M., Brookshaw, A. y Ineson, S. 2014. The probability of the impact of ENSO on precipitation and near-surface temperature. *Climate Risk Management*, 1:5-24.
- Dijkstra, H. A., Petersik, P., Hernández-García, E. y López, C. 2019. The application of machine learning techniques to improve El Niño prediction skill. *Frontiers in Physics*:153.
- 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.

- ENFEN. 2012. Definición operacional de los eventos El Niño y La Niña y sus magnitudes en la costa del Perú. *Nota Técnica ENFEN*.
- Fedorov, A., Harper, S., Philander, S., Winter, B. y Wittenberg, A. 2003. How predictable is El Niño? *Bulletin of the American Meteorological Society*, 84(7):911-920.
- Flores, B. E. 1986. A pragmatic view of accuracy measurement in forecasting. *Omega*, 14(2):93-98.
- Glantz, M., Katz, R. y Nicholls, N. 1991. *Teleconnections linking worldwide climate anomalies*. Cambridge University Press.
- Goddard, L., DeWitt, D. G. y Reynolds, R. W. 2009. Practical implications of uncertainty in observed SSTs. *Geophysical research letters*, 36(9).
- 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.
- Gonzales, E. y Ingol, E. 2021. Determination of a new coastal ENSO oceanic index for northern Peru. *Climate*, 9(5):71. <https://doi.org/10.3390/cli9050071>
- 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):893.
- Ham, Y.-G., Kim, J.-H. y Luo, J.-J. 2019. Deep learning for multi-year ENSO forecasts. *Nature*, 573(7775):568-572.
- Heil, C. E. y Walnut, D. F. 1989. Continuous and discrete wavelet transforms. *SIAM review*, 31(4):628-666.
- Hochreiter, S. y Schmidhuber, J. 1997. Long Short-Term Memory. *In Neural Computation*, 9(8).

- Huang, B., Thorne, P. W., Banzon, V. F., Boyer, T., Chepurin, G., Lawrimore, J. H., Menne, M. J., Smith, T. M., Vose, R. S. y Zhang, H.-M. 2017. Extended reconstructed sea surface temperature, version 5 (ERSSTv5): upgrades, validations, and intercomparisons. *Journal of Climate*, 30(20):8179-8205.
- Hyndman, R. J. 2006. Another look at forecast-accuracy metrics for intermittent demand. *Foresight: The International Journal of Applied Forecasting*, 4(4):43-46.
- Hyndman, R. J. y Koehler, A. B. 2006. Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4):679-688.
- Jamieson, P., Porter, J. y Wilson, D. 1991. A test of the computer simulation model ARCWHEAT1 on wheat crops grown in New Zealand. *Field crops research*, 27(4):337-350.
- Kerr, R. A. 1983. Fading El Niño Broadening Scientists' View: El Niño and its attendant climatic extremes are weakening, leaving specialists looking even farther afield for ultimate causes. *Science*, 221(4614):940-941.
- Kim C.H, C. H. y Kim Y.C, Y. C. 2020. Application of artificial neural network over nickel-based catalyst for combined steam-carbon dioxide of methane reforming (CSDRM). *Journal of Nanoscience and Nanotechnology*, 20(9):5716-5719.
- Kingma, D. P. y Ba, J. 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- 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).
- Kvålseth, T. O. 1985. Cautionary note about R 2. *The American Statistician*, 39(4):279-285.
- Lewis, C. D. 1982. *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth-Heinemann.

- L'Heureux, M. L., Collins, D. C. y Hu, Z.-Z. 2013. Linear trends in sea surface temperature of the tropical Pacific Ocean and implications for the El Niño-Southern Oscillation. *Climate Dynamics*, 40(5):1223-1236.
- L'Heureux, M. L., Takahashi, K., Watkins, A. B., Barnston, A. G., Becker, E. J., Di Liberto, T. E., Gamble, F., Gottschalck, J., Halpert, M. S. y Huang, B. 2017. Observing and predicting the 2015/16 El Niño. *Bulletin of the American Meteorological Society*, 98(7):1363-1382.
- Li, M.-F., Tang, X.-P., Wu, W. y Liu, H.-B. 2013. General models for estimating daily global solar radiation for different solar radiation zones in mainland China. *Energy conversion and management*, 70:139-148.
- Ludescher, J., Gozolchiani, A., Bogachev, M. I., Bunde, A., Havlin, S. y Schellnhuber, H. J. 2013. Improved El Niño forecasting by cooperativity detection. *Proceedings of the National Academy of Sciences*, 110(29):11742-11745.
- Luo, J.-J., Masson, S., Behera, S. K. y Yamagata, T. 2008. Extended ENSO predictions using a fully coupled ocean-atmosphere model. *Journal of Climate*, 21(1):84-93.
- Magnusson, L., Alonso-Balmaseda, M., Corti, S., Molteni, F. y Stockdale, T. 2013. Evaluation of forecast strategies for seasonal and decadal forecasts in presence of systematic model errors. *Climate dynamics*, 41(9):2393-2409.
- Makridakis, S., Wheelwright, S. C. y Hyndman, R. J. 2008. *Forecasting methods and applications*. John wiley & sons.
- Maskey, M., Alemohammad, H., Murphy, K. y Ramachandran, R. 2020. Advancing AI for Earth science: A data systems perspective. *Eos*, 101:25.
- Mason, S. J. y Goddard, L. 2001. Probabilistic precipitation anomalies associated with ENSO. *Bulletin of the American Meteorological Society*, 82(4):619-638.
- McCulloch, W. S. y Pitts, W. 1943. A logical calculus of the idea immanent in neural nets. *Bulletin of Mathematical Biophysics*, 5:115-133.

- McPhaden, M. J. 1999. Genesis and evolution of the 1997 - 98 El Niño. *Science*, 283(5404):950-954.
- McPhaden, M. J. 2002. El Niño and La Niña: Causes and global consequences. *Encyclopedia of global environmental change*, 1:1-17.
- McPhaden, M. J. 2018. Understanding and Predicting El Niño and the Southern Oscillation. *New Frontiers in Operational Oceanography*:653-662.
- Neelin, J. D., Battisti, D. S., Hirst, A. C., Jin, F.-F., Wakata, Y., Yamagata, T. y Zebiak, S. E. 1998. ENSO theory. *Journal of Geophysical Research: Oceans*, 103(C7):14261-14290.
- Newman, M. y Sardeshmukh, P. D. 2017. Are we near the predictability limit of tropical Indo-Pacific sea surface temperatures? *Geophysical Research Letters*, 44(16):8520-8529.
- Nooteboom, P., Feng, Q., López, C., Hernández-García, E. y Dijkstra, H. 2018. Using Network Theory and Machine Learning to predict El Niño. *Earth Syst. Dynam*, (1):1-13. <https://doi.org/10.1002/2017GL074088>
- Olah, C. 2015. Understanding lstm networks. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Pal, M., Maity, R., Ratnam, J., Nonaka, M. y Behera, S. K. 2020. Long-lead prediction of ENSO modoki index using machine learning algorithms. *Scientific reports*, 10(1):1-13.
- Petersik, P. J. y Dijkstra, H. A. 2020. Probabilistic forecasting of El Niño using neural network models. *Geophysical Research Letters*, 47(6):e2019GL086423.
- Petrova, D., Ballester, J., Koopman, S. J. y Rodó, X. 2020. Multiyear statistical prediction of ENSO enhanced by the tropical Pacific observing system. *Journal of Climate*, 33(1):163-174.

- Philander, S. 1990. El Niño, La Niña, and the Southern Oscillation. *Geological Magazine*, 127(5):478-478.
- Ramiah, M. 2019. Convolution Neural Network The backbone of image classification. <https://madhuramiah.medium.com/convolution-neural-network-the-backbone-of-image-classification-ddd2a49a6efa>
- Ramírez, I. J. y Briones, F. 2017. Understanding the El Niño costero of 2017: The definition problem and challenges of climate forecasting and disaster responses. *International Journal of Disaster Risk Science*, 8(4):489-492.
- 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.
- 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.
- Rodriguez, A. 2020. Deep Learning Systems: Algorithms, Compilers, and Processors for Large-Scale Production. *Synthesis Lectures on Computer Architecture*, 15(4):1-265.
- Ropelewski, C. F. y Halpert, M. S. 1987. Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. *Monthly weather review*, 115(8):1606-1626.
- Rosenblatt, F. 1958. Rosenblatt solved the problem with his Perceptron. *Psychological Review*, 65(6):386-408.
- Samuel, A. L. 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3):210-229. <https://doi.org/10.1147/rd.33.0210>
- Sanders, N. R. 1997. Measuring forecast accuracy: some practical suggestions. *Production and inventory management journal*, 38(1):43.

- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K. y Woo, W.-c. 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
- Shi, X. y Yeung, D.-Y. 2018. Machine learning for spatiotemporal sequence forecasting: A survey. *arXiv preprint arXiv:1808.06865*.
- Singh, P. y Manure, A. 2019. *Learn TensorFlow 2.0: Implement Machine Learning and Deep Learning Models with Python*. Apress.
- Takahashi, K. 2017. Fenómeno El Niño: “Global” vs “Costero”. *Boletín técnico: Generación de información y monitoreo del Fenómeno El Niño*, 4(4):4-7.
- Takahashi, K. y Martinez, A. G. 2019. The very strong coastal El Niño in 1925 in the far-eastern Pacific. *Climate Dynamics*, 52(12):7389-7415.
- Takahashi, K., Montecinos, A., Goubanova, K. y Dewitte, B. 2011. ENSO regimes: Reinterpreting the canonical and Modoki El Niño. *Geophysical research letters*, 38(10).
- Takahashi, K., Mosquera, K., Pareja, D., Repou, J. y Aparco, J. 2014. Monitoreo del Pacífico ecuatorial. *Boletín Técnico*, 1(3):8-10.
- Tang, Y., Zhang, R.-H., Liu, T., Duan, W., Yang, D., Zheng, F., Ren, H., Lian, T., Gao, C., Chen, D. *et al.* 2018. Progress in ENSO prediction and predictability study. *National Science Review*, 5(6):826-839.
- Tippett, M. K. y L’Heureux, M. L. 2020. Low-dimensional representations of Niño 3.4 evolution and the spring persistence barrier. *npj Climate and Atmospheric Science*, 3(1):1-11.
- Torrence, C. y Compo, G. P. 1998. A practical guide to wavelet analysis. *Bulletin of the American Meteorological society*, 79(1):61-78.
- Torrence, C. y Webster, P. J. 1999. Interdecadal changes in the ENSO – monsoon system. *Journal of climate*, 12(8):2679-2690.

- Trenberth, K. E. 1997. Bulletin of the American Meteorological Society. *The definition of el nino*, 78(12):2771-2778.
- Trenberth, K. E., Branstator, G. W., Karoly, D., Kumar, A., Lau, N.-C. y Ropelewski, C. 1998. Progress during TOGA in understanding and modeling global teleconnections associated with tropical sea surface temperatures. *Journal of Geophysical Research: Oceans*, 103(C7):14291-14324.
- Walker, G. y Bliss, E. 1932. World Weather V. *Atmospheric and Climate Sciences*, 4(1):53-84.
- 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.
- WMO. 2014. *El Niño/Southern Oscillation*. World Meteorological Agency.
- WMO. 2020. *Guidance on operational practices for objective seasonal forecasting*. World Meteorological Organization.
- Wu, J. 2017. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23):495.
- 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):1-15.
- 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>
- Zeiler, M. D., Krishnan, D., Taylor, G. W. y Fergus, R. 2010. Deconvolutional networks. *2010 IEEE Computer Society Conference on computer vision and pattern recognition*:2528-2535.
- Zhang, Y., Wallace, J. M. y Battisti, D. S. 1997. ENSO - like interdecadal variability: 1900–93. *Journal of climate*, 10(5):1004-1020.

VIII. ANEXOS

Anexo 1: Gráficos de análisis exploratorio y evolución de eventos ENOS (El Niño, La Niña), en distintos periodos.

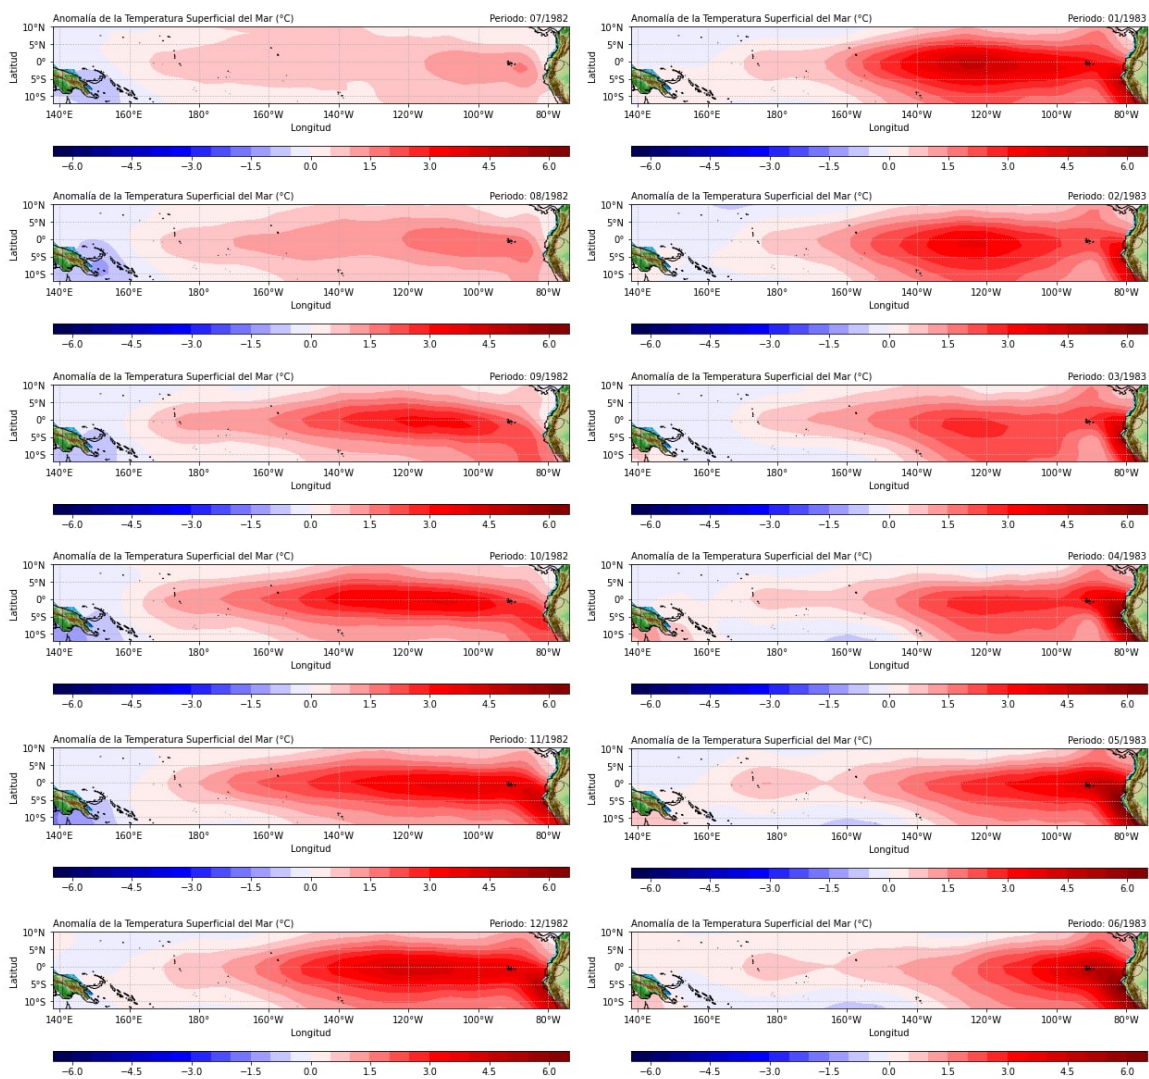


Figura 111: Evolución de las ATSM observado de julio del 1982 a junio del 1983 (Niño extraordinario 1982/83), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

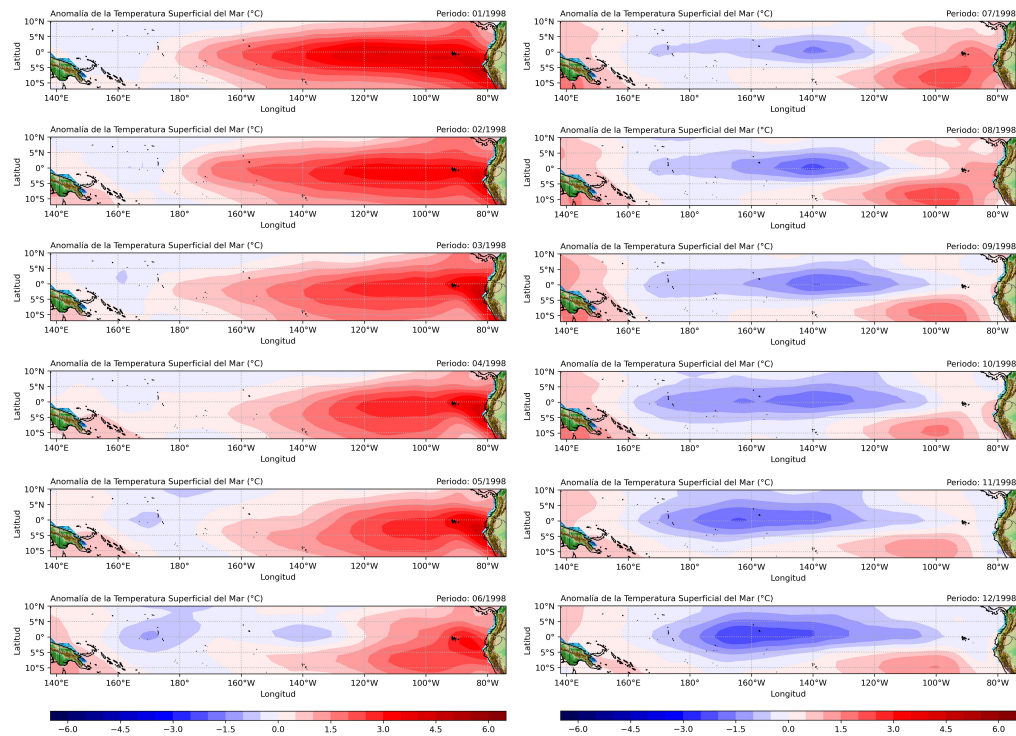


Figura 112: Evolución de las ATSM observado de enero a diciembre de 1998 (Niño extraordinario 1997/98 e inicio de La Niña 1999), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

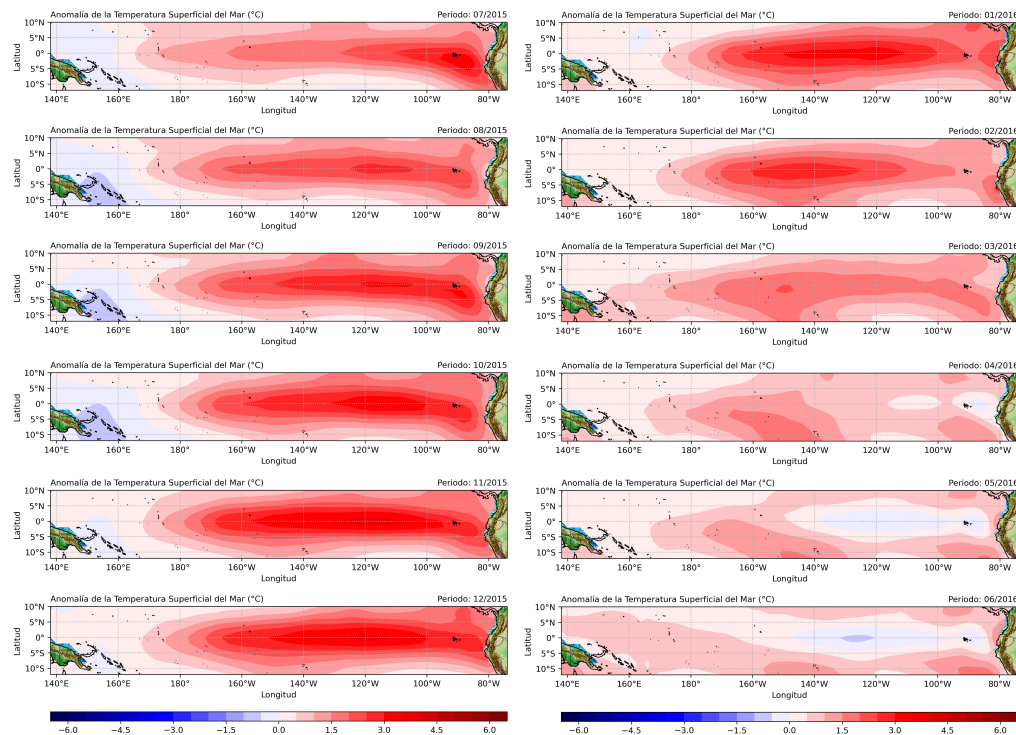


Figura 113: Evolución de las ATSM observado de julio del 2015 a junio del 2016 (Niño 2015/16), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

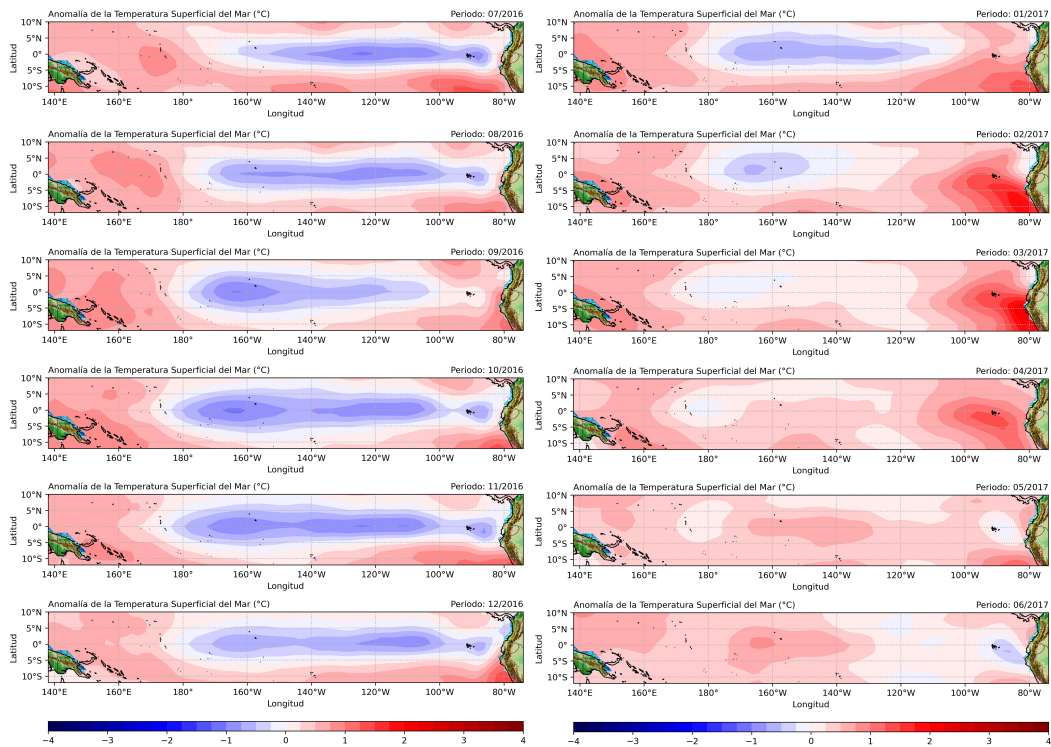


Figura 114: Evolución de las ATSM observado de julio del 2016 a junio del 2017 (Niño Costero 2017), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.

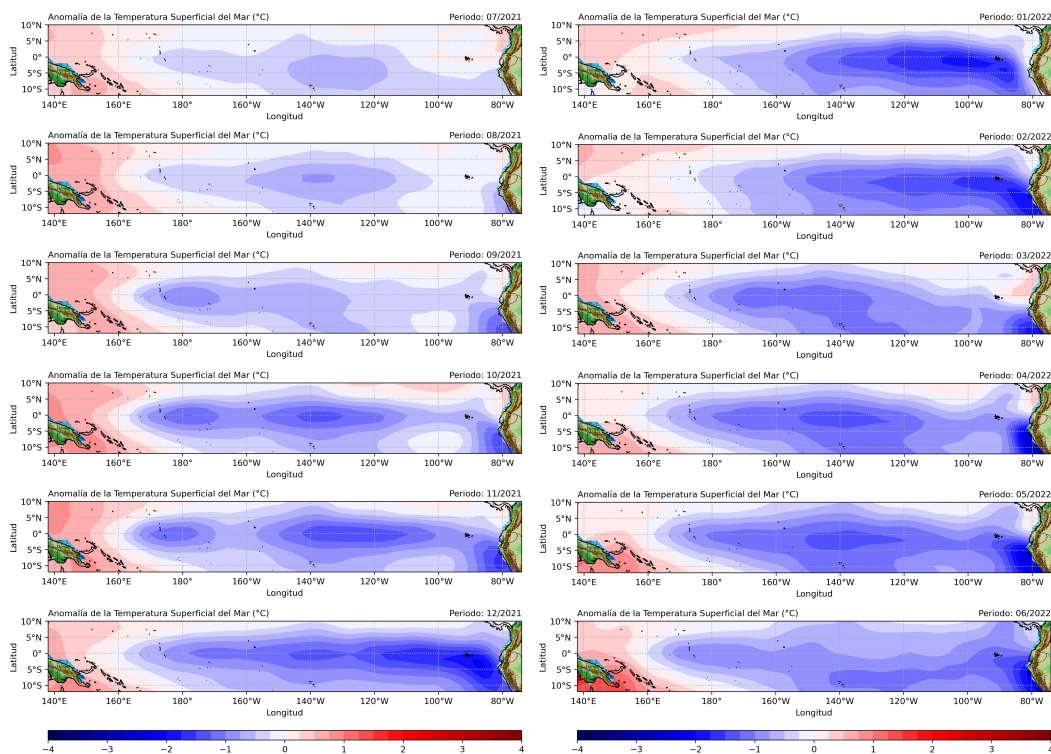


Figura 115: Evolución de las ATSM observado de julio del 2021 a junio del 2022 (La Niña), en el océano Pacífico ecuatorial latitud 10°S–10°N y longitud 140°E–80°W.