

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

FACULTAD DE CIENCIAS



**“FACTIBILIDAD DE LA APLICACIÓN DE TÉCNICAS
DE APRENDIZAJE PROFUNDO PARA LA REGIONALIZACIÓN
ESTADÍSTICA DE TEMPERATURA MÁXIMA Y MÍNIMA EN PUNO”**

Presentada por:

BRUNO RENATO CASTRO SOTO

Tesis para Optar el Título Profesional de:

INGENIERO METEORÓLOGO

Lima – Perú

2024

**La UNALM es la titular de los derechos patrimoniales de la presente investigación
(Art. 24. Reglamento de Propiedad Intelectual)**

Tesis_final

INFORME DE ORIGINALIDAD

17 %	17 %	10 %	10 %
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	1 %
2	rmets.onlinelibrary.wiley.com Fuente de Internet	1 %
3	issuu.com Fuente de Internet	<1 %
4	repositorio.lamolina.edu.pe Fuente de Internet	<1 %
5	core.ac.uk Fuente de Internet	<1 %
6	docplayer.es Fuente de Internet	<1 %
7	journals.ametsoc.org Fuente de Internet	<1 %
8	repositorio.igp.gob.pe Fuente de Internet	<1 %
9	www.senamhi.gob.pe Fuente de Internet	<1 %

Dr Alexis Ibáñez Blancas
Asesor

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

FACULTAD DE CIENCIAS

**“FACTIBILIDAD DE LA APLICACIÓN DE TÉCNICAS
DE APRENDIZAJE PROFUNDO PARA LA REGIONALIZACIÓN
ESTADÍSTICA DE TEMPERATURA MÁXIMA Y MÍNIMA EN PUNO”**

Presentada por:

BRUNO RENATO CASTRO SOTO

Tesis para Optar el Título Profesional de:

INGENIERO METEORÓLOGO

Sustentada y aprobada por el siguiente jurado:

Mg. Sc. Weidi Flores Villanueva
PRESIDENTE

Ph.D. Haline Heidinger Abadía
MIEMBRO

Ph.D. Víctor Levingston Peña Guillén
MIEMBRO

Dr. Alexis Nicolas Ibañez Blancas
ASESOR

DEDICATORIA

A mis padres, Lucía y Fidel, por siempre apoyarme en el largo camino de la carrera universitaria. Ellos han sido mi referente, mi fuente de alegría y motivación.

También quiero mencionar a mis abuelos, mi hermana, primos y tíos, que siempre me apoyaron a lo largo de mi formación profesional.

AGRADECIMIENTOS

Un especial agradecimiento al Dr. Alexis Nicolás Ibañez Blancas, al Mg. Sc. Weidi Flores Villanueva y a todo el jurado calificador, por su permanente guía, apoyo y comprensión en la realización de la presente tesis. Asimismo, un agradecimiento a la Subdirección de Modelamiento Numérico de la Atmósfera (SMN) del SENAMHI, quienes me apoyaron con el recurso computacional, y me absolvieron dudas e inquietudes sobre la investigación.

Esta tesis ha sido desarrollada en el marco del proyecto ENANDES, en coordinación con la Subdirección de Modelamiento Numérico de la Atmósfera (SMN) del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI)



ÍNDICE GENERAL

RESUMEN	vii
ABSTRACT	viii
I. INTRODUCCIÓN	1
1.1. Objetivos.....	3
1.1.1 Objetivo general	3
1.1.2 Objetivos específicos.....	3
II. REVISIÓN DE LITERATURA	5
2.1 Modelos climáticos globales	5
2.1.1 Resolución de los modelos climáticos.....	5
2.1.2 Parametrizaciones.....	6
2.1.3 Dominio del modelo	7
2.2 Cambio climático y calentamiento global	7
2.3 Panel intergubernamental sobre el cambio climático	9
2.4 Escenarios de emisión RCP	10
2.5 Proyecto CMIP5.....	14
2.6 Regionalización estadística	14
2.6.1 Antecedentes de regionalización estadística en el Perú	15
2.6.2 Perfect-Prognosis para regionalización estadística	18
2.7 Inteligencia artificial aplicado a las ciencias atmosféricas.....	19
2.7.1 Las redes neuronales	20
2.8 Metodología de validación cruzada	25
2.9 Esquema de validación para métodos de regionalización (VALUE)	27
2.9.1 Árbol de validación.....	29
2.10TOPSIS.....	30
2.11Reanálisis ERA-5.....	31
2.12Controladores climáticos de Puno	31
2.12.1 Alta de Bolivia	33

2.11.2	Frentes fríos	34
2.11.3	Anticiclones del atlántico sur y norte	37
2.11.4	Lago Titicaca.....	38
III.	METODOLOGÍA.....	39
3.1	Datos y área de estudio.....	39
3.1.1	Variables predictoras	39
3.1.2	Variables predictandos	44
3.2	Preprocesamiento	46
3.3	Entrenamiento.....	47
3.3	Validación.....	47
3.4	Generación de proyecciones	50
IV.	RESULTADOS Y DISCUSIÓN	51
4.1	Análisis de los predictandos	51
4.2	Validación VALUE.....	53
4.2.1	Temperatura máxima.....	53
4.2.2	Temperatura mínima	58
4.3	Validación hold out.....	62
4.3.1	Temperatura máxima	62
4.3.2	Temperatura mínima	65
4.3	Proyecciones climáticas	67
V.	CONCLUSIONES	71
VI.	RECOMENDACIONES	72
VII.	BIBLIOGRAFÍA	73
VIII.	ANEXOS.....	84

ÍNDICE DE TABLAS

Tabla 1: Diferencias entre el cambio climático y el calentamiento global	8
Tabla 2: Escenarios evaluados en los informes del IPCC	11
Tabla 3: Escenarios y trayectorias evaluadas por los grupos de trabajo del IPCC en el AR6.....	13
Tabla 4: Comparación entre las metodologías de regionalización PP y MOD	19
Tabla 5: Técnicas de aprendizaje automático y profundo utilizadas en las ciencias atmosféricas	21
Tabla 6: Métricas usadas para la validación.....	30
Tabla 7: Tipos de frentes y su representación cartográfica.	36
Tabla 8: Lista de variables por controlador climático	40
Tabla 9: Lista de modelos usados en el estudio.....	46
Tabla 10: Métricas usadas para la validación VALUE.....	48
Tabla 11: Estaciones bajo administración del SENAMHI usadas para la validación hold out.....	49
Tabla 12: Estadísticos de los predictandos del dominio	51
Tabla 13: Análisis TOPSIS para temperatura máxima	56
Tabla 14: Análisis TOPSIS para temperatura mínima.....	60
Tabla 15: Estadísticos de validación por estación para la temperatura máxima	63
Tabla 16: Estadísticos de validación por estación para la temperatura mínima	65
Tabla 17: Estadísticos de los predictandos del dominio	68

ÍNDICE DE FIGURAS

Figura 1. Representación espacial del sistema tierra atmósfera por los GCM	6
Figura 2. Modelos climáticos globales acoplados	7
Figura 3. Anomalía de temperatura promedio anual para américa latina	10
Figura 4. Comparación de los escenarios evaluados en los informes del IPCC.....	11
Figura 5. Escenarios de emisión considerados en el AR6	13
Figura 6. Estructura de una red neuronal simple de 3 capas	20
Figura 7. Tipos de aprendizaje automático	23
Figura 8. Arquitectura de la CNN para detección de imágenes	24
Figura 9. Técnica de Validación Cruzada “hold out” sobre el 80% del total de la muestra de datos.....	26
Figura 10. Esquematación del árbol de validación	29
Figura 11. Mapa del departamento de Puno.....	32
Figura 12. Distribución del Alta de Bolivia para el mes de enero.....	34
Figura 13. Representación de un frente en la cartografía meteorológica.....	36
Figura 14. Modelo de CGA para un planeta con continentes.....	37
Figura 15. Secado progresivo del lago Titicaca	38
Figura 16. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 1.....	41
Figura 17. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 2.....	42
Figura 18. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 3.....	43
Figura 19. Dominio de los predictandos del producto PISCO	44
Figura 20. Flujograma del proceso de regionalización estadística de escenarios climáticos	45
Figura 21. Ubicación espacial de las estaciones del SENAMHI empleadas	50

Figura 22. Comparación entre el periodo de entrenamiento y prueba para la temperatura máxima	52
Figura 23. Comparación entre el periodo de entrenamiento y prueba para la temperatura mínima	53
Figura 24. Comparación de los métodos de regionalización estadística para la temperatura máxima	55
Figura 25. Comparación espacial de los métodos de regionalización estadística para la temperatura máxima.....	57
Figura 26. Comparación de los métodos de regionalización estadística para la temperatura mínima	59
Figura 27. Comparación espacial de los métodos de regionalización estadística para la temperatura mínima	61
Figura 28. Promedios mensuales para la temperatura máxima por estación	63
Figura 29. Variabilidad mensual de la temperatura máxima por estación	64
Figura 30. Promedios mensuales para la temperatura mínima por estación	66
Figura 31. Promedios mensuales para la temperatura mínima por estación	67
Figura 32. Análisis de regresión Theilsen para la temperatura máxima	69
Figura 33. Análisis de regresión Theilsen para la temperatura mínima.....	70

ÍNDICE DE ANEXOS

Anexo 1: Validación de estaciones meteorológicas bajo administración del SENAMHI en el departamento de Puno.	85
Anexo 2: Comparación entre valores simulados y observados para la temperatura promedio diaria.	89
Anexo 3: Proyecciones climáticas del CMIP a nivel mensual	91

RESUMEN

En la presente investigación se evalúan las técnicas de aprendizaje profundo (*Deep Learning* en inglés), para la regionalización estadística de proyecciones climáticas generadas por el modelo CanESM5 del proyecto CMIP5. Asimismo, se verificaron los resultados de las técnicas de aprendizaje profundo usando métricas del marco de validación VALUE (e.g., razón de la desviación estándar, BIAS y correlación de Pearson), antes de aplicarlas a las proyecciones climáticas. Las técnicas aplicadas fueron las Redes Neuronales Convolucionales (CNN por sus siglas en inglés) de “complejidad creciente” para regionalizar la temperatura máxima y mínima sobre el departamento de Puno. Las CNN se compararon con otra técnica usada frecuentemente para regionalización estadística, que son los modelos de regresión lineal simple y generalizada (GLM por sus siglas en inglés). Además, se analiza el rol de los distintos elementos que constituyen la arquitectura de una red neuronal convolucional con la finalidad de evaluar su capacidad para proyectar el clima futuro; lo cual es de gran relevancia para su aplicación en la generación de escenarios de cambio climático local, debido a su menor costo computacional respecto a la técnica ampliamente conocida de regionalización dinámica. Los resultados de la validación obtenidos tras entrenar un conjunto de CNN son que el modelo de redes neuronales convolucionales que capta las relaciones lineales entre los predictores y predictandos (CNN-LM) es el que mejor representa la temperatura máxima y el modelo que capta relaciones no lineales con un número decreciente de mapas de características (CNN1) el que mejor representa la temperatura mínima. Finalmente, se concluye que es posible aplicar la técnica de CNN para la regionalización estadística de temperatura máxima y mínima a dos metros de la superficie, tanto a nivel climatológico como para las proyecciones futuras, en la zona correspondiente al altiplano en el departamento de Puno, que abarca la ladera oriental, la cordillera oriental y occidental.

Palabras claves: Aprendizaje profundo, Modelos climáticos globales, regionalización estadística, *Convolutional Neural Networks*, Escenarios de cambio climático, CMIP5.

ABSTRACT

In this research, deep learning techniques are evaluated for the statistical regionalization of climate projections generated by the CanESM5 model of the CMIP5 project. Likewise, the results of the deep learning techniques were verified using metrics from the VALUE validation framework (e.g., standard deviation ratio, BIAS and Pearson correlation), before applying them to the climate projections. The techniques applied were Convolutional Neural Networks (CNN) of “increasing complexity” to regionalize the maximum and minimum temperature over the department of Puno. CNNs were compared with another frequently used technique for statistical regionalization, which are simple and generalized linear regression models (GLM). Furthermore, the role of the different elements that constitute the architecture of a convolutional neural network is analyzed in order to evaluate its capacity to project the future climate; which is of great relevance for its application in the generation of local climate change scenarios, due to its lower computational cost compared to the widely known technique of dynamic regionalization. The validation results obtained after training a set of CNNs are that the convolutional neural network model that captures the linear relationships between the predictors and predictands (CNN-LM) is the one that best represents the maximum temperature and the model that captures non-linear relationships with a decreasing number of feature maps (CNN1) which best represents the minimum temperature. Finally, it is concluded that it is possible to apply the CNN technique for the statistical regionalization of maximum and minimum temperature two meters from the surface, both at a climatological level and for future projections, in the area corresponding to the highlands in the department of Puno. covering the eastern slope, the eastern and western mountain range.

Keywords: Deep learning, Global climate models, statistical regionalization, Convolutional Neural Networks, Climate change scenarios, CMIP5.

I. INTRODUCCIÓN

Se requiere una enorme capacidad computacional para simular el clima a larga escala, esto limita a los modelos climáticos globales (GCM, por sus siglas en inglés) a elaborar proyecciones de gruesa resolución espacial y temporal; las cuales son útiles para entender el cambio climático a nivel global y continental, pero poseen limitaciones al aplicarse a una región en específico (Vandal *et al.*, 2017). En este contexto, los métodos de *downscaling* o regionalización se presentan como una técnica que permite mejorar la resolución de los GCM y generar información útil para escalas locales (Benestad *et al.*, 2007).

En esencia, estos métodos se pueden dividir en 2 grandes grupos: dinámicos y estadísticos. Los métodos dinámicos de regionalización juntan la gruesa resolución de las proyecciones generadas por los GCM y los procesos regionales para construir un modelo climático regional (RCM, por sus siglas en inglés) (Vandal *et al.*, 2017). Los métodos estadísticos se basan en establecer relaciones entre variables atmosféricas a larga escala (predictores) y variables locales/regionales de interés (predictandos), generando un modelo capaz de estimar las variables locales en función a las variables atmosféricas de larga escala (Baño-Medina *et al.*, 2019). Los RCM requieren un alto costo computacional y no se pueden generalizar fácilmente para aplicarse en otras regiones, ya que los factores que influyen el clima local varían de un lugar a otro (Vandal *et al.*, 2017). Asimismo, a las salidas de los RCM se les puede aplicar *downscaling* estadístico (SD, por sus siglas en inglés). Por tanto, estas 2 técnicas se pueden considerar como complementarias más que mutuamente excluyentes (Bedia *et al.*, 2019).

Para el presente estudio se usarán las proyecciones obtenidas por los modelos climáticos globales generados por el proyecto de comparación de modelos acoplados fase 5 (CMIP5, por sus siglas en inglés) para proyectar el clima futuro.

Es importante indicar que los GCM usan parametrizaciones para incluir los procesos que ocurren a una escala menor a la que el modelo puede detectar, es decir procesos a subgrilla

(Benestad *et al.*, 2007). Por esto, es importante evaluarlos y verificar la correcta representación del clima de la región.

Debido a que en Sudamérica se presenta un mayor déficit de información, comparado con otros continentes del hemisferio norte, hay que ser cuidadosos al momento de elegir qué modelo del CMIP5 se va a utilizar (Barreto Schuler, 2016). De modo que, se evaluaron las salidas de los modelos del CMIP5 para verificar la representación de los sistemas sinópticos característicos de la región de Sudamérica, y su influencia en el departamento de Puno.

En el Perú, existen antecedentes de regionalización estadística de escenarios climáticos (SENAMHI, 2014), en donde probaron distintas técnicas, dominios espaciales y variables apropiadas para el *downscaling* de temperatura máxima, mínima y precipitación. Uno de los modelos evaluados fue el CanESM5 del CMIP5, que también será utilizado en esta investigación, ya que (i) no tenía valores perdidos por la orografía, (ii) presentaba una de las mejores resoluciones de referencia en comparación con los otros modelos evaluados y (iii) tenía importantes mejoras respecto a su versión del CMIP3 (e.g., mejora de la representatividad de los patrones de circulación atmosférica a gran escala, mayor sensibilidad del modelo a la combinación del forzamiento natural y antropogénico).

La generación de escenarios futuros con una resolución más fina permite evaluar, de manera más detallada y con mucha anticipación, ciertos eventos meteorológicos que afectan seriamente al departamento de Puno (e.g., friajes, heladas, sequías, precipitaciones extremas). Mediante regionalización estadística se busca obtener proyecciones a 10 km de resolución espacial y a escala diaria, para analizar la ocurrencia de estos eventos en el futuro.

Por otro lado, el aprendizaje profundo (*Deep Learning*) es un tipo de aprendizaje automático (*Machine Learning*) que entrena a la computadora para que realice tareas y mejore su rendimiento a través de la experiencia (Hernández, 2019). Ha tenido importantes avances en el reconocimiento del habla, identificación de imágenes y en hacer predicciones (Hernández, 2019). En el campo de datos espacio temporales, como los utilizados en las ciencias atmosféricas, las técnicas de aprendizaje profundo surgen como una aproximación promisorio a la regionalización estadística, debido a su capacidad de representar características de alto nivel en forma jerárquica (Baño-Medina *et al.*, 2019).

Una vez generado el modelo de regionalización estadística se validará mediante la técnica de validación cruzada, que considera un conjunto de datos independientes para el periodo de entrenamiento y de prueba (SENAMHI, 2014). Asimismo, la validación de métodos de

downscaling es categorizado cómo un problema “multifacético”, que involucra muchos aspectos cómo la representación de los extremos o la estructura espacial y temporal (Baño-Medina *et al.*, 2019). Por esto, el Proyecto de Validación Value (VPP, por sus siglas en inglés) se creó para validar métodos de regionalización y mejorar la colaboración entre las comunidades que aplican esta metodología, en este contexto se desarrollaron una lista de índices y medidas que permiten la evaluación de la mayoría de los aspectos mencionados previamente, utilizando como base la técnica de validación cruzada (Maraun D. *et al.*, 2015a).

En este estudio se busca evaluar la idoneidad de las CNN para el *downscaling* estadístico de escenarios climáticos generados por el CMIP5 en el departamento de Puno. Para este fin, se entrenaron varios modelos con esta técnica en un periodo histórico (1981:2005) y luego se validaron con otro periodo diferente (2006:2010) para evitar el sobreajuste. Además, se realizó un procedimiento similar con otro método que usualmente se utiliza para regionalización estadística (GLM4, regresión lineal generalizada con 4 grillas cercanas) y se compararon los resultados obtenidos por medio del método de decisión multicriterio por similitud a la solución ideal (TOPSIS, por sus siglas en inglés). Posteriormente, se aplicó el modelo con el que se obtuvo mejores resultados a las proyecciones climáticas generadas por el CanESM5 del CMIP5 en el departamento de Puno, para obtener una resolución más fina.

1.1. Objetivos

1.1.1 Objetivo general

- Determinar la factibilidad del empleo de las CNN para la regionalización estadística de temperatura máxima y mínima en el departamento de Puno, tanto a nivel climatológico como para proyecciones futuras.

1.1.2 Objetivos específicos

- Validar los modelos de CNN con la técnica de validación cruzada usando las métricas del marco “VALUE”, definiendo un periodo de entrenamiento (1981:2005) y otro de corroboración (2006:2010), para evitar sobreajuste.
- Realizar regionalización estadística de la temperatura máxima y mínima a 2 metros de la superficie a las salidas del modelo ERA-5 y CMIP5, a partir de las variables predictoras temperatura, humedad específica, altura geopotencial, viento zonal y meridional en 4 niveles de presión (850, 700, 200 y 300 hPa).

- Aplicar el modelo a las proyecciones climáticas generadas por el modelo CanESM5 del proyecto CMIP5 (2021:2040) para obtener una resolución más fina.

II. REVISIÓN DE LITERATURA

2.1 Modelos climáticos globales

Los GCM son representaciones matemáticas del sistema climático que se basan en la resolución de ecuaciones de las leyes y principios de la física (CSIRO, 2020). De esta manera, mediante los GCM se pueden describir los sistemas sinópticos (e.g., Anticiclón del pacífico sur, zona de convergencia intertropical, vaguada tropical de alta troposfera) que influyen en una región (Benestad *et al.*, 2007).

Los componentes principales representados por los modelos climáticos son: i) la atmósfera, que tiene un rol importante en el transporte de calor y humedad a lo largo del globo, ii) superficie terrestre, que incluye la vegetación, nieve, ríos, agua en el suelo, etc, iii) océano, que es una de las mayores reservas de calor y carbón del sistema climático, y iv) el hielo marino, que regula la absorción de radiación solar y la interacción océano atmósfera (Brunke, 2011).

2.1.1 Resolución de los modelos climáticos

El cálculo de las ecuaciones que gobiernan la dinámica del sistema climático (e.g., ley general de los gases ideales, conservación de la masa, energía y momento) dan como resultado las siguientes variables: i) temperatura del aire, ii) presión atmosférica, iii) densidad, iv) contenido de vapor de agua en el aire y la magnitud del viento en tres direcciones (Eltahir & Krol, 2021). Estas variables antes mencionadas son simuladas en tres dimensiones espaciales (longitud, latitud y altura), representadas como grillas distribuidas a lo largo de toda la superficie de la tierra, y una dimensión temporal (NOAA, 2023). El Figura 1 muestra las grillas simuladas por un GCM, que definen la resolución del modelo; es decir, a mayor cantidad de grillas el modelo tiene mayor resolución y también requiere de un recurso computacional más potente (Brunke, 2011).




Figura 1. Representación espacial del sistema tierra atmósfera por los GCM
FUENTE: NOAA, 2023.

2.1.2 Parametrizaciones

Las ecuaciones numéricas no pueden resolver correctamente los procesos cuyo tamaño sea menor que las grillas del modelo, es decir, a una escala subgrilla o subrejilla; estos procesos son representados por los GCM mediante parametrizaciones, que incluyen la influencia de la vegetación, evapotranspiración, procesos radiativos, etc (Gerard, 2007). Las ecuaciones y parametrizaciones se resuelven y aplican para cada uno de los componentes del sistema climático (atmósfera, hidrósfera, criósfera, biósfera y litósfera), creando de esta manera un modelo del clima global con acoplamiento (MCGC); esto se puede ver esquemáticamente en Figura 2 (Benestad *et al.*, 2007; CSIRO, 2020).

2.1.3 Dominio del modelo

Se refiere a un área definida por 3 dimensiones (longitud, latitud y altura), está dividido por grillas ordenadas en forma rectangular, como si fuesen una cuadrícula. Debido a que el modelo divide al mundo por grillas, el dominio se puede traducir cómo la región del planeta que se desea evaluar (Meteoblue, 2018).

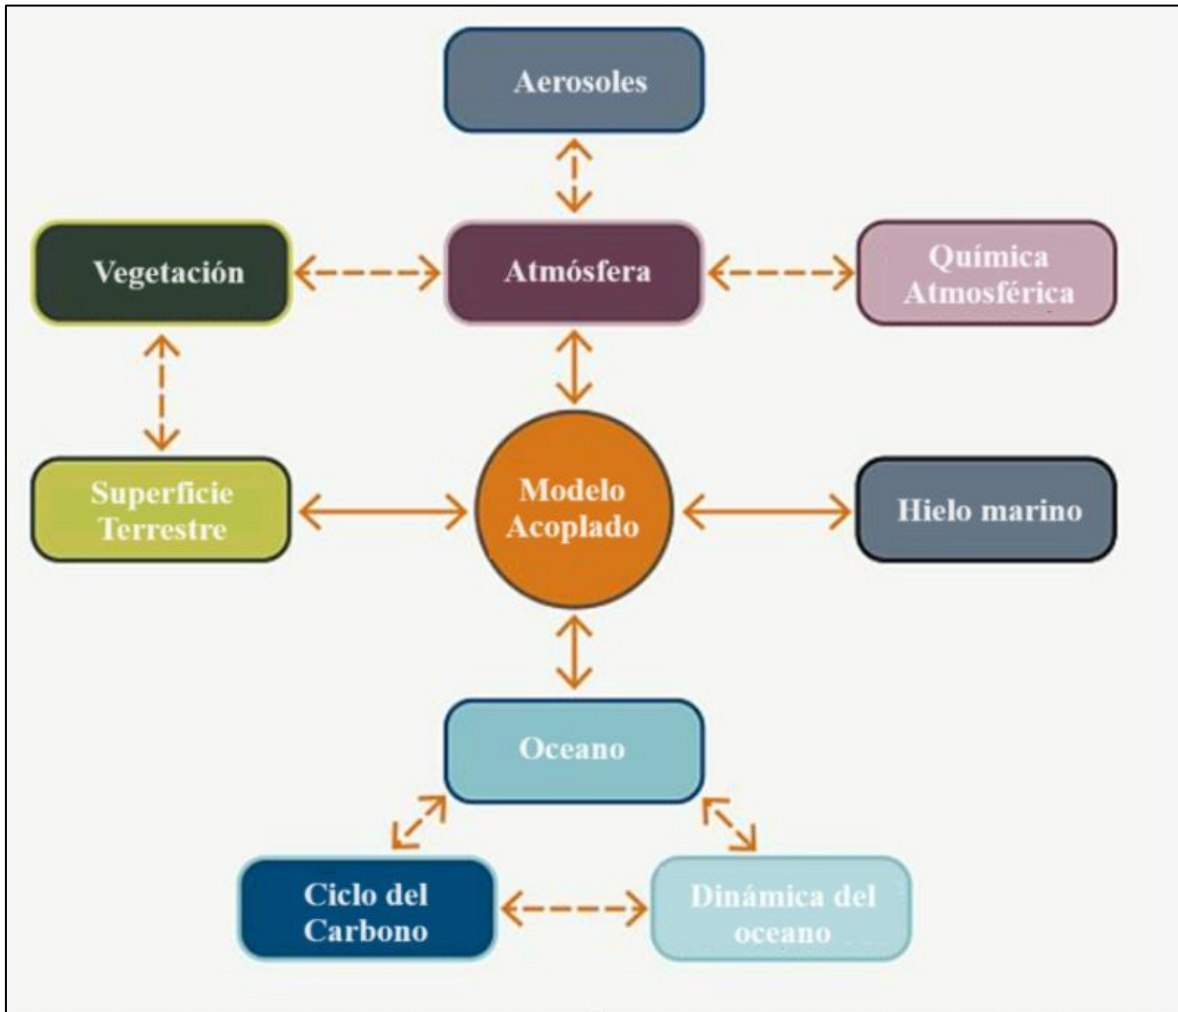


Figura 2. Modelos climáticos globales acoplados
FUENTE: CSIRO, 2020.

2.2 Cambio climático y calentamiento global

El cambio climático es definido como la variación a largo plazo de los patrones atmosféricos promedio que determinan los climas locales, regionales y globales (NASA, 2023). El calentamiento global, por su parte, hace referencia al aumento de la temperatura superficial de la tierra (Kennedy & Lindsey, 2018). Estos términos suelen ser usados de manera indistinta; sin embargo, tienen diferentes definiciones, en la Tabla 1 se muestra un cuadro comparativo con ambos conceptos.

Tabla 1: Diferencias entre el cambio climático y el calentamiento global

Cambio climático	Calentamiento global
Cambio a largo plazo de los patrones climáticos	Calentamiento a largo plazo de la superficie de la tierra.
Término general para referirse a los cambios en el clima.	Observado desde el periodo pre-industrial (entre 1850 y 1900).
Debido a factores naturales (e.g., actividad volcánica, variación de la órbita de la tierra, eventos ENSO¹) y antropogénicos.	Debido a actividades humanas, principalmente quema de combustibles fósiles.
Incluye al calentamiento global y sus efectos secundarios.	Tiene efectos secundarios, como el derretimiento de glaciares, eventos extremos más frecuentes, etc.

NOTA:

¹ EL NIÑO OSCILACIÓN SUR

FUENTE: Kennedy & Lindsey, 2018; NASA, 2023.

El calentamiento global se produce debido a la elevada concentración de Gases de Efecto Invernadero (GEI) en la atmósfera (e.g., dióxido de carbono, metano, óxido nitroso, clorofluorocarbonos y hexafluoruro de azufre), que retienen el calor y aumentan progresivamente la temperatura de la tierra (MINAM, 2009). Este calentamiento de la superficie de la temperatura de la tierra contribuye al cambio climático. Según el IPCC, (2014) las emisiones de GEI hechas por el hombre dependen de los siguientes factores:

- Tamaño de la población.
- Actividad económica.
- Estilo de vida.
- Uso de energía.
- Patrones de uso del suelo.
- Tecnología.
- Política climática.

2.3 Panel intergubernamental sobre el cambio climático

El Panel Intergubernamental sobre el Cambio Climático (IPCC, por sus siglas en inglés) es el organismo de las naciones unidas encargado de evaluar la ciencia relacionada con el cambio climático. Se creó para proporcionar a los encargados de formular políticas, evaluaciones científicas periódicas sobre el cambio climático, sus implicaciones y posibles riesgos futuros (IPCC, 2023).

Las observaciones del estado físico de la atmósfera que se realizan a lo largo del mundo proveen datos fundamentales para evaluar y comprender las causas de la variabilidad y el cambio climático; aquellas han dado suficiente evidencia para que el IPCC difunda que el calentamiento climático global es algo inequívoco (WMO, 2022). Aunque existen mecanismos que de manera natural generan alteraciones en el clima, el cambio climático observado desde 1950 hasta la actualidad tiene como causa dominante las actividades humanas (NASA, 2023).

La temperatura es uno de los indicadores climáticos más importantes; para caracterizarla el IPCC usa anomalías calculadas a partir de un periodo de referencia, que suele ser el de 1850 – 1900 para que esté relacionado a la era preindustrial. Sin embargo, debido a la disponibilidad de datos este periodo de referencia preindustrial no puede ser utilizado como línea base en todas las regiones. Por esto, en el informe sobre el estado del clima de América Latina y el Caribe elaborado por la Organización Meteorológica Mundial (WMO, 2023), se recomienda utilizar el periodo de referencia del 1961 – 1990 para evaluar el cambio de la temperatura a largo plazo y el periodo de 1991 – 2020 para cálculo de climatología¹.

Al evaluar el promedio anual de las anomalías se observa un aumento de 0.50 °C para el año 2022 respecto al periodo de 1961-1990; el periodo de 1991 – 2022 muestra mayor tendencia de calentamiento (aproximadamente 0.2 °C) comparada con los periodos de referencia previos (e.g., 1900 – 1930, 1931 – 1960 y 1961 - 1990) en la región de América Latina y el Caribe (WMO, 2023). En la Figura 3 se observan las anomalías anuales que demuestran lo mencionado previamente. Por tanto, aunque no se pueda comparar con la era preindustrial,

¹ Este periodo de referencia para cálculo de climatología fue actualizado por la OMM en el año 2021 ([Updated 30-year reference period reflects changing climate | World Meteorological Organization \(wmo.int\)](https://www.wmo.int))

en América Latina se observa un aumento significativo de la temperatura medida a 2 metros de la superficie desde 1961 hasta la actualidad.




Figura 3. Anomalía de temperatura promedio anual para América Latina
FUENTE: WMO, 2023.

2.4 Escenarios de emisión RCP

En el quinto informe del IPCC (2014) se han definido 4 escenarios de emisión, denominados trayectorias de concentración representativas (RCP, por sus siglas en inglés); que se caracterizan por su forzamiento radiativo para el año 2100 y van desde $2.6 - 8.5 \text{ W/m}^2$. El forzamiento radiativo es una medida del cambio neto en el balance de radiación de la tierra debido a perturbaciones naturales y antropogénicas (Cubasch *et al.*, 2013). En la Figura 4 se muestra la comparación entre los RCP y los escenarios usados en las evaluaciones previas del IPCC, en la Tabla 2 se muestran los informes del IPCC y sus escenarios asociados.




Figura 4. Comparación de los escenarios evaluados en los informes del IPCC

RF: Forzamiento Radiativo.

FUENTE: Cubasch *et al.*, 2013.

Tabla 2: Escenarios evaluados en los informes del IPCC

Informe del IPCC ¹	Escenarios simulados	Modelos acoplados ²	Año de publicación	Detalles
AR 5	RCP2.6, RCP4.5, RCP6 y RCP8.5	CMIP5	2013	Provee una base científica para el acuerdo de Paris (2015).
AR 4	SRES A1B, A2 y B1	CMIP3	2007	Sentó las bases para un acuerdo posterior al Protocolo de Kyoto, centrado en limitar el calentamiento a 2°C.

Continuación ...

TAR	SRES A1B, A1FI, A1T, A2, B1 y B2	CMIP2	2001	Se centra en los impactos del cambio climático y la necesidad de adaptación
SAR	IS92a, IS92b, IS92c, IS92d, IS92e e IS92f	CGCM	1995	Prepara a los gobiernos para la adopción del Protocolo de Kyoto, posteriormente aprobado en 1997.
FAR	IS92a, IS92b, IS92c, IS92d, IS92e e IS92f	CGCM	1990	Aborda el tema de cambio climático como un reto con consecuencias globales y que requiere cooperación internacional.

NOTAS:

¹FAR: Primer informe del IPCC, SAR: Segundo Informe del IPCC, TAR: Tercer Informe del IPCC, AR 4: Cuarto Informe del IPCC Y AR5: Quinto Informe del IPCC.

²el proyecto de intercomparación de modelos acoplados (CMIP) se creó en 1995; sin embargo, antes de este el IPCC también usaba modelos acoplados Oceano-Atmósfera (CGCM).

FUENTE: Cubasch *et al.*, 2001, 2013; Houghton *et al.*, 1992.

En los cinco primeros informes del IPCC los escenarios simulados (e.g., RCP, SRES, IS92) se diferencian por las emisiones de GEI a la atmósfera y por el forzamiento radiativo. En el sexto informe del IPCC (AR6) se cambian las trayectorias de concentración representativas a los escenarios de desarrollo socio económico (SSP, por sus siglas en inglés), que de manera similar a las RCP se diferencian por las emisiones de GEI a la atmósfera. Los SSP considerados en el AR6, ordenados de menor a mayor emisión de GEI, son los siguientes (IPCC, 2023): SSP1-1.9, SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5. En la Figura 5 se muestran los SSP y en la Tabla 3 se describen las equivalencias entre los RCP y SSP.

Es importante indicar que los SSP del AR6 cubren una mayor cantidad de escenarios simulados que los RCP, con una gama más amplia de emisiones de GEI y contaminantes atmosféricos (Calvin *et al.*, 2023). Asimismo, el forzamiento radiativo en general tiende a ser mayor en los escenarios SSP en comparación con los RCP con la misma etiqueta (Calvin *et al.*, 2023).

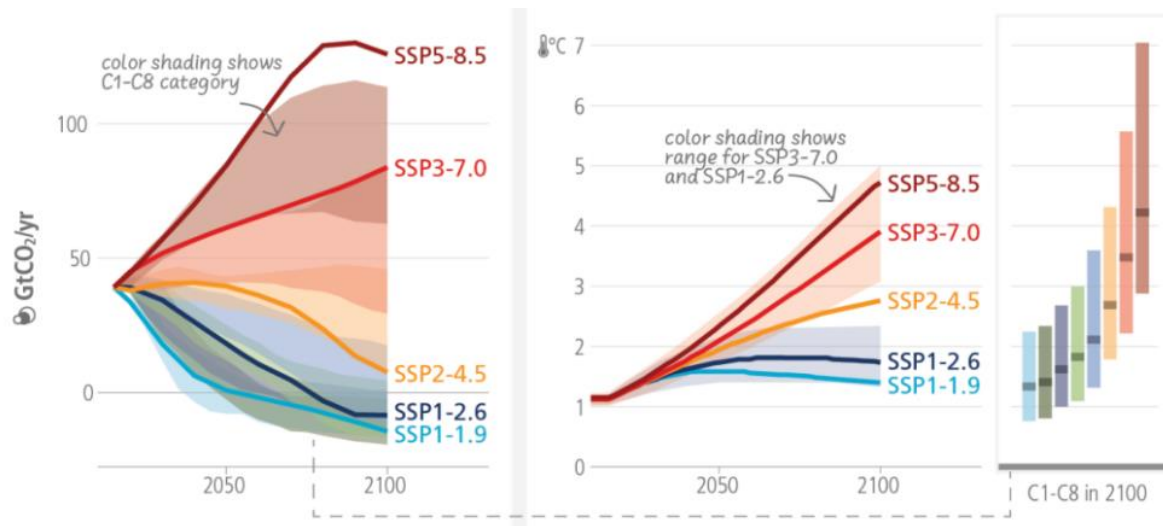


Figura 5. Escenarios de emisión considerados en el AR6
FUENTE: Calvin *et al.*, 2023.

Tabla 3: Escenarios y trayectorias evaluadas por los grupos de trabajo del IPCC en el AR6

Categoría SSP (Cx)	Descripción de la categoría ¹	Escenario de emisión de GEI (SSPx-y ²)	RCPy
C1	Limitar el calentamiento a 1.5 °C con una probabilidad mayor al 50%	Muy baja emisión de GEI (SSP1-1.9)	
C2	Retornar el calentamiento a 1.5 °C con una probabilidad mayor al 50%		
C3	Limitar el calentamiento a 2 °C con una probabilidad mayor al 67%	Baja emisión de GEI (SSP1-2.6)	RCP2.6
C4	Limitar el calentamiento a 2 °C con una probabilidad mayor al 50%		
C5	Limitar el calentamiento a 2.5 °C con una probabilidad mayor al 50%		
C6	Limitar el calentamiento a 3 °C con una probabilidad mayor al 50%	Emisión intermedia de GEI (SSP2-4.5)	RCP4.5
C7	Limitar el calentamiento a 4 °C con una probabilidad mayor al 50%	Alta emisión de GEI (SSP3-7.0)	
C8	Exceder el calentamiento de 4 °C con una probabilidad mayor al 50%	Muy alta emisión de GEI (SSP5-8.5)	RCP8.5

¹Todas las categorías hacen referencia a limitar el calentamiento cierta cantidad de grados celsius al año 2100, con cierta probabilidad de ocurrencia.

²“x” Se refiere a la trayectoria de desarrollo socioeconómico SSP E “y” Hace referencia al nivel de forzamiento radiativo.

FUENTE: Calvin *et al.*, 2023.

2.5 Proyecto CMIP5

El proyecto de Inter comparación de modelos acoplados (CMIP) se estableció como un protocolo experimental estándar para estudiar la producción de modelos de circulación general océano-atmosféricos acoplados (AOGCM, por sus siglas en inglés). Prácticamente toda la comunidad internacional de modeladores climáticos ha participado en este proyecto desde su inicio en 1995. Debido a que los AOGCM permiten que el clima simulado se ajuste a los cambios en el forzamiento climático, como el aumento del dióxido de carbono atmosférico (WCRP, 2020), la quinta fase del CMIP (CMIP5) permitió una actualización en los escenarios futuros relacionados a los posibles efectos del calentamiento global, y los resultados fueron considerados en el Quinto Informe del IPCC (AR5). Asimismo, en el sexto informe del IPCC (AR6) se utilizaron los modelos del CMIP6.

El proyecto CMIP está compuesto por varios MIP (*Model Intercomparison Projects*), que son distintos experimentos que tienen por objetivo responder preguntas del sistema tierra atmósfera como el SIMIP (*Sea-Ice Model Intercomparison Project*), CORDEX (*Coordinated Regional Climate Downscaling Experiment*), OMIP (*Ocean Model Intercomparison Model*), entre otros. Estos experimentos son desarrollados por varios centros de modelamiento a lo largo del mundo, lo cual permite obtener una gran lista de variables del sistema tierra atmósfera (CMIP, 2023). Los modelos acoplados del CMIP son corridos varias veces variando ligeramente las condiciones iniciales, estas corridas son conocidas como miembros del ensamble (*ensembles*) y tienen las siguientes características: i) índice de regularización, que identifica las condiciones iniciales, ii) índice de inicialización, que se refiere al procedimiento de inicialización, iii) índice físico, que se refiere a las condiciones físicas usadas por el modelo, y iv) índice de forzamiento (e.g., forzamiento natural, RCP, SSP) (Taylor *et al.*, 2022).

2.6 Regionalización estadística

A pesar de que los modelos climáticos globales proporcionan información útil sobre el cambio climático a escala global, estos presentan limitaciones en la resolución espacial y temporal cuando se aplican a nivel regional (SENAMHI, 2014). Para obtener una visión más detallada del cambio climático en regiones específicas, se utilizan técnicas de regionalización estadística con el fin de generar escenarios de cambio climático de alta resolución (Benestad *et al.*, 2007). La obtención de un conocimiento detallado de las

condiciones climáticas actuales y la estimación de las proyecciones climáticas en el futuro son elementos imprescindibles para la toma de decisiones en diferentes sectores de la sociedad (Llamocca Huamani, 2022). Además, son fundamentales para llevar a cabo evaluaciones de impactos y riesgos en los distintos sectores sensibles al cambio climático, así como para el desarrollo de planes nacionales de adaptación, políticas y medidas sectoriales (Morata-Gasca, 2014).

De manera general, los métodos de regionalización se dividen en 2 grandes grupos: estadísticos y dinámicos. El primero se basa en crear relaciones estadísticas entre predictores y predictandos. El segundo se genera a partir de la integración de la gruesa resolución de modelos climáticos globales y los procesos locales en un modelo climático regional (RCM, por sus siglas en inglés) (Vandal *et al.*, 2017). Al crear un RCM, se focalizan más en los procesos regionales que influyen el clima local, en cambio en la regionalización estadística se asume que las relaciones históricas entre los patrones de circulación a gran escala y el clima local se mantienen constantes (Benestad *et al.*, 2007). La desventaja de la regionalización dinámica es su alto costo computacional y económico, además que no permiten una generalización del modelo a otras regiones, ya que los procesos que determinan el clima local varían de un lugar a otro (Vandal *et al.*, 2017).

El método de regionalización estadística se basa en la relación entre las variables climáticas globales y regionales, lo que permite obtener información detallada y de alta resolución a escala local a partir de los resultados de los modelos climáticos globales (IPCC, 2001). Las variables de gran escala se les denomina como predictores y suelen ser obtenidas de los modelos globales; las variables de pequeña escala son los predictandos y suelen ser medidas directamente por instrumental meteorológico (Bedia *et al.*, 2019). El proceso de regionalización detecta relaciones empíricas entre los predictores y predictandos; para después aplicarlas a los predictores simulados por los modelos climáticos globales, es decir a los pronósticos estacionales, multi-decadales o proyecciones climáticas, para obtener valores regionales de interés (Baño-Medina *et al.*, 2019).

2.6.1 Antecedentes de regionalización estadística en el Perú

El Perú se encuentra entre los países más vulnerables a los eventos climáticos, según los estudios realizados por Brooks & Adger (2003). Esta vulnerabilidad se debe a la ubicación geográfica del país, su diversidad ecológica y su alta dependencia de sectores primarios

sensibles al cambio climático, como la agricultura y la pesca, así como a un bajo nivel institucional que dificulta la planificación y ejecución de acciones de adaptación concretas.

En este contexto, se han llevado a cabo importantes estudios de modelado para generar escenarios climáticos futuros en Perú. Un ejemplo temprano es el trabajo de Sanabria *et al.*, (2009), que se centró en el desarrollo y evaluación de un modelo de aproximación que simula posibles cambios futuros en la precipitación y la temperatura en el Altiplano peruano para el período 2071-2100, para este propósito, se emplearon tres RCM (ETA CCS, HadRM3 y REgCM3) y se examinaron las variables de precipitación y temperatura. Los resultados indicaron que el modelo HadRM3 fue el que mejor representó la estacionalidad y los valores climatológicos de la precipitación, reproduciendo los períodos húmedos y secos, aunque con una sobreestimación de 2 mm/día (Sanabria *et al.*, 2009). En cuanto a la temperatura, tanto el HadRM3 como el ETA CSS simularon la tendencia de la estacionalidad de la climatología de la temperatura, con el segundo relativamente mejor que el primero, ambos subestimándola en 5°C y 4°C, respectivamente (Sanabria *et al.*, 2009). A pesar de la dificultad en la simulación de la lluvia en los Andes, debido a la complejidad en la parametrización de la topografía, el modelo HadRM3 logró presentar errores menores que los otros modelos (Sanabria *et al.*, 2009). Esta información es una primera aproximación del cambio climático futuro en el Altiplano peruano, que puede ser utilizada para estudios de impacto de cambio climático en la agricultura y la hidrología; para comprender mejor la variabilidad climática actual y proyectarla hacia el futuro.

Asimismo, en un estudio propuesto por Hofer *et al.*, (2015) se presenta un método de reducción de escala estadística (SD) para cadenas montañosas glaciares de gran altitud. El método utiliza datos de temperatura media diaria del aire en la Cordillera Blanca, Perú, como variables objetivo y datos de reanálisis como predictores. Los resultados muestran que la habilidad del modelo SD para predecir la temperatura del aire varía estacionalmente, con la mejor habilidad durante los meses de la estación húmeda y de transición, y la peor habilidad durante los meses de la estación seca. Se requieren al menos 40 a 140 observaciones por mes para obtener habilidades estadísticamente significativas. Además, se ha observado que la habilidad del modelo aumenta en relación con la disponibilidad de datos. La evaluación identifica la temperatura del aire y la altura geopotencial como los únicos predictores significativos para la temperatura del aire a escala local. La contabilidad de la periodicidad natural en los datos es crucial para evitar rendimientos falsamente altos de ciertos

predictores. Este método puede aplicarse a diferentes entornos climáticos y geoambientales, sin el requisito de optimización subjetiva.

En el año 2019 se desarrollaron métodos de reducción estadística para evaluar la disponibilidad de agua en las cuencas de Chillón, Rímac, Lurín y Alto Mantaro en el período 2036-2065 (De la Cruz & Acuña, 2019). Los modelos estadísticos se basaron en un método de analogía para la precipitación y en regresiones lineales múltiples para las temperaturas máximas y mínimas. Se exploraron 10 dominios geográficos y un conjunto de 33 predictores para la precipitación y las temperaturas extremas de ubicaciones representativas en las cuencas. Los resultados muestran un aumento significativo de la precipitación media en un rango de 20 a 100 mm bajo un escenario de emisiones moderado (RCP 4.5) y alto (RCP 8.5). El aumento más pronunciado de la cantidad de precipitación se produce durante el invierno en la cuenca del Alto Mantaro, lo que podría alterar la disponibilidad futura de agua. En cuanto a la temperatura máxima, los valores oscilan entre 1°C y 4°C, siendo los cambios más pronunciados los correspondientes al escenario de emisiones más alto. Es importante destacar que el evidente aumento de las temperaturas en las regiones de tierras altas de estas cuencas podría tener un impacto significativo en los ecosistemas y glaciares ubicados en estas regiones.

Por otro lado, en el año 2021, se publicó un estudio en el que se desarrolló un modelo empírico-estadístico de reducción de escala (ESD) para predecir la distribución espacial de la lluvia en los Andes centrales del Perú durante el verano austral (Sulca *et al.*, 2021). Este modelo utiliza técnicas de regresión lineal múltiple basadas en índices de circulación a gran escala que representan la variabilidad climática del Océano Pacífico tropical, el Océano Atlántico y América del Sur para estimar la precipitación durante el verano austral. Los análisis estadísticos muestran que el modelo ESD puede reproducir las anomalías de precipitación observadas en los Andes tropicales, la cuenca ecuatorial oriental del Amazonas y la parte central de los Andes occidentales argentinos. Además, el modelo ESD también reproduce condiciones anormalmente secas sobre la Amazonía ecuatorial oriental y las condiciones húmedas sobre el sureste de América del Sur durante los extremos de El Niño. La adición de los forzamientos del Océano Atlántico ecuatorial y la Zona de Convergencia del Atlántico Sur en el modelo ESD mejora la estimación de las anomalías de precipitación en los Andes centrales del Perú y la Amazonía peruana. Los resultados obtenidos en este estudio pueden ser útiles para el desarrollo de medidas de mitigación para eventos hidroclimáticos extremos, incluido El Niño (Sulca *et al.*, 2021).

Recientemente, se ha llevado a cabo una investigación que se enfoca en la aplicación de técnicas de regionalización estadística para obtener mapas regionalizados de las proyecciones climáticas de precipitación, temperatura máxima y mínima del aire para Perú, considerando los escenarios climáticos del Quinto Reporte de Evaluación-AR5-2014 del IPCC-RCP45 & RCP85. Se seleccionaron cuatro modelos climáticos globales (ACCESS1-0, MPI-ESM-LR, IPSL-CM5A-MR y CESM1-CAM5) del Proyecto de Intercomparación de Modelos Acoplados fase 5 (CMIP5) mediante la aplicación de métricas estadísticas y se analizaron las proyecciones bajo los dos escenarios para el periodo futuro 2041-2070. Los hallazgos sugieren un panorama favorable, centrados en la selva baja norte, centro y sur del Perú, con incrementos de 2.0 °C a 3.8 °C en las temperaturas máximas y de 1.7 °C a 3.0 °C en las temperaturas mínimas (IPCC, 2014). En cuanto a la precipitación, se observan incrementos significativos en un 20% para la costa norte y centro de Perú, mientras que para la costa sur y la selva baja se prevén reducciones anuales del -20%. Estas proyecciones sugieren impactos climáticos significativos, como sequías prolongadas y tormentas locales severas, en la selva baja y la costa sur oriental (Llamocca Huamani, 2022).

2.6.2 Perfect-Prognosis para regionalización estadística

Los métodos de downscaling estadístico, se pueden clasificar de acuerdo con la aproximación seguida en la fase de entrenamiento: Perfect Prognosis (PP) y Model Output Statistics (MOS) (Bedia *et al.*, 2019). En la PP, el modelo estadístico se calibra usando data observada para los predictores y predictandos; mientras que en el MOS se emplean únicamente los datos del GCM o RCM para los predictores (Ramon *et al.*, 2021). En la Tabla 4 se muestran las principales diferencias entre ambas aproximaciones.

Tabla 4: Comparación entre las metodologías de regionalización PP y MOD

<i>Perfect Prognosis (PP)</i>	<i>Model Output Statistic (MOD)</i>
Usa datos observados y simulados por los GCM como variables predictoras.	Las variables predictoras son extraídas de los GCM.
Genera los pronósticos con las condiciones futuras calculadas por los GCM, asumiendo que son “predicciones perfectas”.	Corrige los errores (BIAS) de los GCM antes de generar las proyecciones, mediante escalamiento lineal, mapeo quantile-quantile. etc.
Solo se emplea información climatológica para en el desarrollo de las ecuaciones.	Emplea información de las proyecciones de los GCM en el desarrollo de las ecuaciones.
Se asemeja al desarrollo de las ecuaciones de regresión clásicas, en la que los predictores observados son usados para calcular los predictandos observados.	Se le aplica corrección por BIAS a las salidas de los GCM para que se ajusten más a los datos observados.
Usa ecuaciones de regresión múltiple	Usa ecuaciones de regresión múltiple

FUENTE: Bedia *et al.*, 2019; Wilks, 2007.

2.7 Inteligencia artificial aplicado a las ciencias atmosféricas

La inteligencia artificial (IA) podría definirse cómo la habilidad de las máquinas de usar algoritmos para aprender de los datos y utilizar lo aprendido para descubrir patrones, tendencias o incluso tomar decisiones tal cómo lo haría una persona (Rouhiainen, 2008). Debido a esto, las IA tienen varias aplicaciones dentro de las ciencias atmosféricas; cómo la predicción de heladas meteorológicas (Mercado *et al.*, 2016), estimación de la intensidad de ciclones (Pradhan *et al.*, 2018), detección de ríos atmosféricos (Chapman *et al.*, 2019), predicción de precipitación (Nourani *et al.*, 2019), etc.

El término IA es general y abarca un conjunto bastante numeroso de técnicas, algoritmos y metodologías. Por esto, en las siguientes secciones se desarrollarán los subcampos más relevantes en el área de ciencias atmosféricas.

2.7.1 Las redes neuronales

Las redes neuronales artificiales son sistemas de procesamiento fuertemente inspirados en la forma en que el sistema nervioso humano funciona, están compuestas por nudos computacionales, que se refiere a las neuronas, que están interconectadas y distribuidas para aprender de manera óptima de los datos de entrada y dar un mejor resultado (O'Shea & Nash, 2015).

Las redes neuronales son el algoritmo más conocido de la inteligencia artificial, ya que es con este que se han logrado los resultados más exitosos, lo cual se debe a su versatilidad y gran flexibilidad para la aplicación en diversas tareas (Quintero Plaza, 2022). Su estructura básica se puede observar en la Figura 6.




Figura 6. Estructura de una red neuronal simple de 3 capas

FUENTE: O'Shea & Nash, 2015.

En el Figura 6 se observa una red neuronal con 3 capas: la capa de entrada (*Input Layer*) tiene 4 neuronas, la capa oculta (*Hidden Layer*) tiene 2 neuronas y la de salida (*Output Layer*) está compuesta por 1 neurona. En este caso la red neuronal es *fully connected* y *feedforward*, ya que todas las neuronas de las capas están conectadas entre sí, pero no hay retroalimentación “hacia atrás” (Bagnato, 2020).

2.7.1.1 Metodologías de aprendizaje

Existen diversas metodologías de aprendizaje automático (*machine learning*) que se pueden escoger dependiendo de la tarea que se vaya a realizar. En la Tabla 5 se observa un resumen de algunas técnicas que vienen siendo utilizadas en las ciencias atmosféricas.

Tabla 5: Técnicas de aprendizaje automático y profundo utilizadas en las ciencias atmosféricas

Clasificación	Modelo	Aplicación	Referencia
Machine Learning	Regresión lineal simple y múltiple	Predicción de temperatura, velocidad del viento, precipitación, contaminantes atmosféricos, etc.	(Karna <i>et al.</i> , 2021)
	<i>Random Forest</i>	Estimación de precipitación	(Wolfensberger <i>et al.</i> , 2021)
Deep Learning	<i>Fully connected networks</i>	Simulación de la capa límite planetaria	(Wang <i>et al.</i> , 2019)
	<i>Convolutional Neural Networks</i>	Regionalización estadística de temperatura y precipitación	(Baño-Medina <i>et al.</i> , 2019)
	<i>Convolutional Neural Networks</i>	Estimación de la intensidad de ciclones	(Pradhan <i>et al.</i> , 2018)
	<i>Recurrent neural networks</i>	Predicción de data climática local	(Han <i>et al.</i> , 2021)

Los métodos de *machine learning* (aprendizaje automático) suelen ser utilizados para extraer patrones y detectar características de los datos, sin embargo, estas aproximaciones pueden no ser las más óptimas cuando el comportamiento del sistema está gobernado por sus variaciones espaciales y temporales; en estos casos es mejor usar métodos de *deep learning*

(aprendizaje profundo) porque son capaces de extraer las características espacio temporales de los datos (Reichstein *et al.*, 2019).

2.7.1.1.1 Aprendizaje automático

El aprendizaje automático (*machine learning* en inglés) puede definirse como un enfoque de la inteligencia artificial que permite que un programa por sí mismo, es decir sin intervención humana y en forma automatizada, aprenda a descubrir patrones, tendencias y relaciones en los datos, y gracias a ello mejore automáticamente (Bagnato, 2020). Esta definición nos indica que este método tiene por objetivo lograr que la máquina aprenda a partir de la experiencia, es decir no busca generar una ecuación para que con ciertos inputs calcule un resultado; sino que sea capaz de identificar patrones y relaciones entre los datos mediante algoritmos.

El aprendizaje automático se divide en 3 subconjuntos: aprendizaje supervisado, no supervisado y de refuerzo (Rouhiainen, 2008). En el Figura 7 se puede ver de manera esquemática los tipos de aprendizaje automático y una descripción de cada uno.

- En el aprendizaje supervisado los datos de entrada están etiquetados y contienen la solución deseada, es así que se requiere cierta intervención humana para indicarle a la máquina que es exactamente lo que se requiere clasificar, predecir, detectar, etc (O'Shea & Nash, 2015).
- En el aprendizaje no supervisado no se utilizan datos previamente etiquetados, sino que el algoritmo tiene que aprender a clasificarlos por su cuenta; lo cual no requiere de intervención humana y la máquina es capaz de detectar varios patrones del conjunto de dato de entrada (O'Shea & Nash, 2015), esto debido a que no se le especificó algo en particular.
- En el aprendizaje por refuerzo los algoritmos aprenden de la experiencia, es decir que cada vez que aciertan se les provee de un “refuerzo positivo” para indicarles que ese es el resultado deseado, de esta forma lo pueden detectar y predecir cada vez de manera más certera (Rouhiainen, 2008).

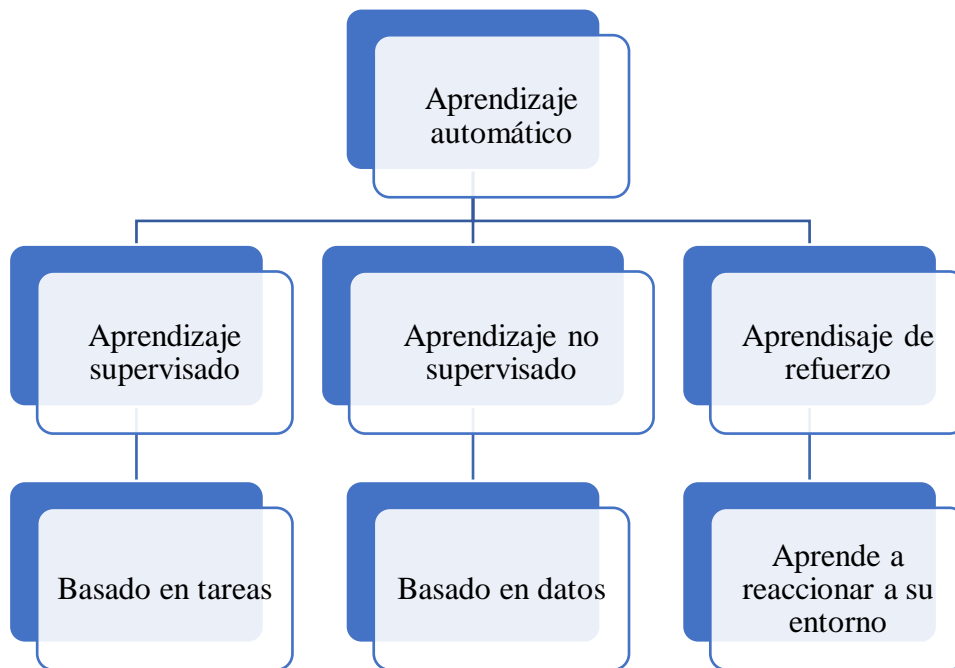


Figura 7. Tipos de aprendizaje automático
FUENTE: Rouhiainen, 2008.

2.7.1.1.2 Aprendizaje profundo

La estructura básica de los algoritmos de aprendizaje profundo (*Deep Learning*, en inglés) se basa en la de las redes neuronales artificiales, estas conexiones están caracterizadas por un peso que se aprende de la data y que se ajustan automáticamente para optimizar el resultado obtenido en la capa de salida (output layer) (Baño-Medina *et al.*, 2019). La diferencia del Deep learning con las redes neuronales tradicionales (machine learning) radica en el número de capas; mientras que las convencionales tienen 2 o 3 capas, en el aprendizaje profundo se pueden utilizar cientos de capas (Bhoumik, 2018). A continuación, se describen los métodos más utilizados.

- Las Fully Connected Network, se basan en la arquitectura de las redes neuronales clásicas; e implica que todas las neuronas de las capas están conectadas entre sí. De acuerdo con Wang *et al.*, (2019), este modelo obtuvo predicciones con una buena correlación en comparación con las salidas del WRF (Weather Research Forecast) para la temperatura, velocidad del viento y perfil vertical de vapor de agua.
- Las Convolutional Neural Networks (CNN), es un tipo de red neuronal artificial con aprendizaje supervisado que procesa sus capas imitando al córtex visual del ojo humano para identificar distintas características. Para ello, la CNN contiene varias capas ocultas especializadas y con una jerarquía: esto quiere decir que las primeras capas pueden detectar formas simples, como líneas o curvas, y se van especializando hasta llegar a

capas más profundas que reconocen formas complejas, como un rostro o la silueta de un animal (Bagnato, 2020).

- La arquitectura de una CNN consiste en 3 tipos de capas: convolucionales, pooling y fully connected. Las convolucionales, aplican a la imagen de entrada un conjunto de filtros que detectan ciertas características de esta, a cada una de estas capas se le puede aplicar una función de activación ReLU, que permite un entrenamiento más efectivo convirtiendo los valores negativos a 0 y manteniendo los valores positivos; las capas pooling simplifican la salida, reduciendo el número de parámetros que la red necesita para aprender (Bhoumik, 2018). Este proceso se repite varias veces en cientos de capas y se van detectando poco a poco distintas características cada vez más complejas. Finalmente, en la capa fully connected se “conecta” con una red neuronal tradicional, ya que se “aplana” la última capa oculta, que era tridimensional, y se convierte en un vector que le aplicaremos una función llamada Softmax, que conectará con la capa final, la cual contiene las neuronas correspondientes a lo que estamos clasificando (Bagnato, 2018). Lo anteriormente descrito se puede observar esquemáticamente en la Figura 8.
- Las Recurrent Neural Networks (RNN), son una clase de red neuronal más sofisticada diseñada para modelar relaciones complejas en las series de tiempo; pueden procesar data multivariada como input, extraer características y generar salidas multivariadas (Han *et al.*, 2021). Sin embargo, requieren un mayor costo computacional en comparación con las otras técnicas.

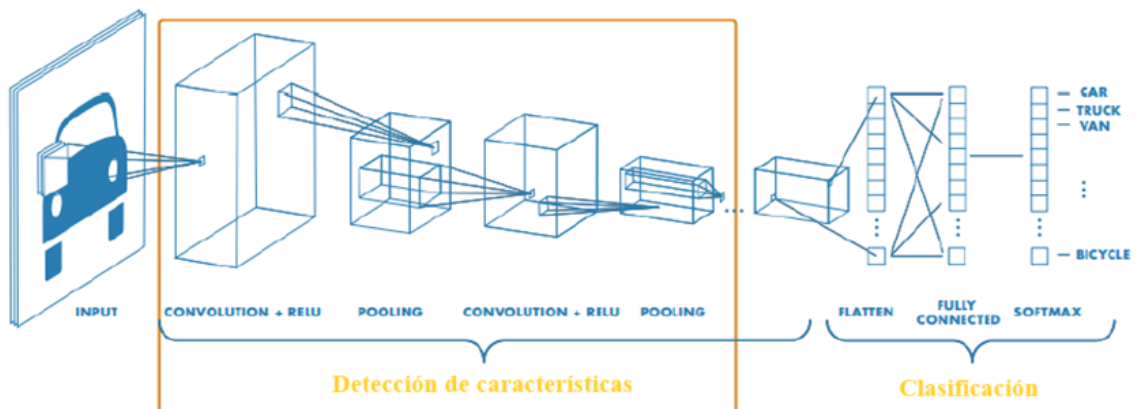


Figura 8. Arquitectura de la CNN para detección de imágenes
FUENTE: Bhoumik, 2018.

2.8 Metodología de validación cruzada

Existen diversas técnicas para validar los resultados de los modelos, esto con el objetivo de probar su efectividad y hallar los parámetros que maximizan el rendimiento de los algoritmos de predicción (Brunelli, 2014). Algunas de las técnicas usadas son: la re-sustitución, la estratificación o el uso de validación cruzada, que incluyen *Holdout*, validación cruzada de K particiones, validación cruzada dejando uno fuera, entre otros.

La validación cruzada se desarrolló para cuantificar la habilidad predictiva de los modelos estadísticos en la década de 1930 y se ha vuelto ampliamente utilizada con la llegada de las computadoras modernas (Efron & Gong, 1983; Stone, 1974). Además, se ha convertido en una herramienta estándar en la predicción del tiempo y el clima (Jolliffe & Stephenson, 2011; Mason, 2008; Michaelsen, 1987).

La validación cruzada o “*cross validation*” es un método estadístico que permite evaluar y comparar algoritmos de aprendizaje por medio de la división de datos, lo cual reduce el sesgo y la variabilidad en la estimación del rendimiento del modelo (Moons *et al.*, 2015). La forma básica de validación cruzada consiste en la división de un conjunto de muestras de datos en dos segmentos mediante el método *split-sample*; en uno de ellos se desarrolla el aprendizaje o entrenamiento del modelo, y con el otro este es validado (Rodríguez, 2019).

El método de validación “*Hold-out*” es el más práctico de todos. Consiste en separar el conjunto de datos disponibles en dos partes, un subconjunto es utilizado para entrenar el modelo y el otro para validar su efectividad (Arlot & Celisse, 2010); de esta manera, se crea un modelo únicamente con los datos de entrenamiento. Este genera datos de salida que posteriormente se comparan con el otro subconjunto aislado de datos para realizar la prueba de validación (Hawkins *et al.*, 2003). Los estadísticos obtenidos con los datos del subconjunto de validación son los que nos dan la validez real del método empleado en términos de error.

El objetivo principal de este método es eliminar la habilidad artificial: si el modelo estadístico se evalúa con los mismos datos que se utilizan para la calibración, el rendimiento para predecir nuevos datos casi con seguridad será inferior a la habilidad estimada. Por lo tanto, el modelo se calibra solo en un subconjunto de los datos y se evalúa en otro, idealmente independiente, subconjunto de los datos (Maraun D. & Widmann, 2018).

La forma más común de aplicar la técnica de validación cruzada *hold out* es dejar entre el 10% al 20% de las muestras para realizar la evaluación y entrenar el 80% al 90% restante, lo cual se observa esquemáticamente en el Figura 9.

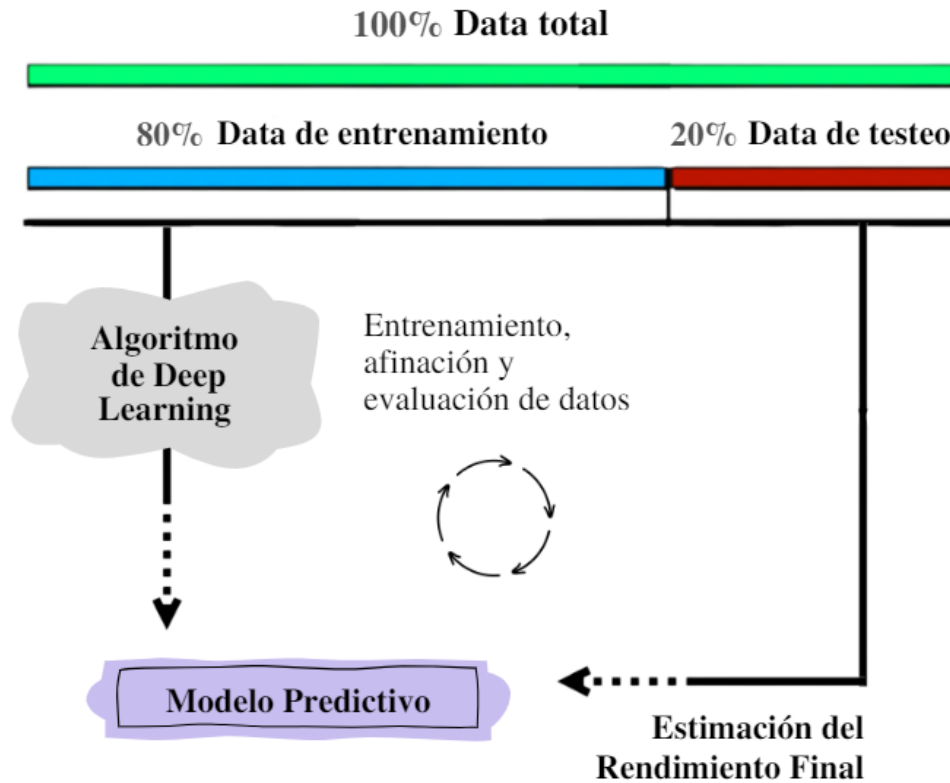


Figura 9. Técnica de Validación Cruzada “hold out” sobre el 80% del total de la muestra de datos

Una aplicación alternativa de este método consiste en repetir un determinado número de veces el proceso “*hold-out*”, tomando distintos conjuntos de datos de entrenamiento de manera aleatoria. Estos métodos de validación cruzada son los casos especiales de *k*-folds cross validation y Leave-One-Out cross validation (LOOCV). Los cuales consisten en segmentar un conjunto de datos en “*k*” grupos o pliegues de igual o similar tamaño, y se sigue la misma metodología que se ha explicado en el método de *cross validation* básico. Se utilizan *k*-1 subconjuntos para el entrenamiento del modelo y el subconjunto restante se utiliza como grupo de validación. Este procedimiento se repite “*k*” veces en rondas sucesivas de modo que cada punto de datos tenga la posibilidad de ser validado (Rodríguez, 2019). El resultado se obtiene tras una optimización en cada iteración, acotando la probabilidad de error estimado como promedio de los errores en cada iteración (Hurtado, 2007).

Estas últimas metodologías presentan una grave desventaja, puesto que la división aleatoria de un pequeño conjunto de datos para el análisis implica la casi segura pérdida de información que no podrá ser recuperada, además, de inducir riesgo sobre el rendimiento

óptimo (Gong, 1986). Aunque en cada iteración se hace un promedio del error producido, existe poca o nula representatividad de las muestras (Gong, 1986).

2.9 Esquema de validación para métodos de regionalización (VALUE)

Nuestra comprensión del cambio climático global se basa principalmente en modelos de circulación general (GCM, por sus siglas en inglés) con una resolución relativamente baja. Dado que los impactos del cambio climático se experimentan principalmente a escala regional, es necesario derivar escenarios de cambio climático de alta resolución a partir de simulaciones de GCM mediante reducción de escala (Ahmed *et al.*, 2013). En estudios de adaptación basados en escenarios de clima futuro, existen dos enfoques distintos para reducir los resultados de modelos de circulación general (GCM): la regionalización dinámica, que se basa en el uso de un modelo climático regional (RCM, por sus siglas en inglés) y la regionalización estadística, que utiliza modelos estadísticos para relacionar la circulación a gran escala de los GCM con la evolución de variables meteorológicas locales. De acuerdo con Gómez-Navarro *et al.*, (2011), pese a que la regionalización dinámica ha mostrado mejoras en los procesos meso escalares en regiones con fuertes forzamientos superficiales (topografía compleja, heterogeneidad en usos del suelo, interfase tierra-mar, etc) y aportes de información sobre fenómenos que no cubren los GCM, como los episodios extremos de contaminación, o la precipitación convectiva que conduce a episodios extremos de lluvia, este tipo de reducción de escala es computacionalmente costosa. Por lo tanto, no siempre es factible realizar una regionalización dinámica a la resolución espacial requerida, especialmente si se desean predicciones de múltiples modelos. Además, es probable que los resultados de los RCM también contengan sesgos que deban eliminarse (Chen *et al.*, 1999; Marinucci & Giorgi, 1992).

Por el contrario, la regionalización estadística se considera una herramienta de uso común en los estudios de impacto, ya que es computacionalmente eficiente y puede utilizarse adecuadamente para realizar la reducción de escala espacial y la corrección de sesgo para una gran cantidad de resultados de GCM. Para ello, se establecen relaciones empírico-estadísticas durante un período de control, que luego se aplican a un período más amplio (Benestad *et al.*, 2007). El método utilizado en este estudio para realizar esta calibración se basa en el uso de redes neuronales convolucionales (CNN).

La mayoría de los enfoques estadísticos de reducción de escala se desarrollan en base a la suposición de que la relación estadística entre los resultados de GCM a gran escala y los

datos de observación a escala fina establecidos para el clima actual permanecerán sin cambios en el clima futuro (Boé *et al.*, 2006; Wilby *et al.*, 1998). Para la temperatura, los métodos convencionales de regionalización estadística utilizan la relación empírica entre las variables predictoras basadas en la circulación a gran escala (altura geopotencial, temperatura del aire, viento zonal y meridional, humedad específica, etc.) y las variables climáticas regionales (temperatura máxima y temperatura mínima) que deben estimarse (Feddersen & Andersen, 2005; Wilby & Wigley, 2000; Zorita & von Storch, 1999).

Para un escenario de emisión dado, la habilidad de las proyecciones regionales de cambio climático está limitada por las incertidumbres, principalmente debido a los errores del modelo y la variabilidad climática interna (Stainforth *et al.*, 2007). En el contexto de la reducción de escala (*downscaling* o regionalización), la cuestión de la habilidad hace referencia principalmente al rendimiento en la simulación de los datos de entrada por los GCM para las proyecciones regionales de cambio climático, y a la efectividad en el funcionamiento de los métodos de *downscaling* bajo un contexto de cambio climático y la relación señal-ruido entre las tendencias del cambio climático y la variabilidad climática interna a escala regional (Maraun D. *et al.*, 2015b). En respuesta a ello, Déqué *et al.*, (2007) mostró que el error en los resultados de modelos de circulación general son una fuente importante de incertidumbre en las proyecciones climáticas regionales. Es por ello que debería considerarse un diseño de validación en particular más allá de la gran cantidad de métodos estadísticos de reducción de escala desarrollados por climatólogos, hidrólogos y estadísticos individuales (Maraun D. *et al.*, 2010). Además, la validación debería tomar en cuenta aspectos como los eventos extremos, las dependencias espaciotemporales y las relaciones entre variables. El diseño experimental de validación, la elección de las variables meteorológicas y los aspectos a validar deben guiarse por los requisitos del usuario.

En este contexto, la Cooperación de la Unión Europea en Ciencia y Tecnología (EU COST) Action ES1102 VALUE estableció una red abierta para validar sistemáticamente e intercomparar enfoques de *downscaling* para la investigación del cambio climático, centrándose en diferentes aspectos de validación (marginal, temporal, extremos, espacial, procesual, etc.). VALUE tiene como objetivo desarrollar un marco común para la validación de métodos de *downscaling* entre las comunidades de investigación dispersas y fomentar la colaboración e intercambio de conocimientos entre partes interesadas para establecer una comunidad interdisciplinaria de reducción de escala (Maraun D. *et al.*, 2015b).

2.9.1 Árbol de validación

Una validación consiste en derivar índices climáticos a partir de los resultados del modelo, comparar estos índices con índices de referencia calculados a partir de datos de observación y cuantificar el desajuste con la ayuda de medidas de desempeño adecuadas (Maraun D. *et al.*, 2015b).

Para guiar la selección de índices, VALUE ha desarrollado un árbol de decisión para la selección de índices relevantes y medidas de desempeño (Figura 10), comenzando por la elección de fenómenos relevantes para el problema en consideración. Estos pueden ser eventos de precipitaciones o temperaturas extremas, temporada de crecimiento u olas de calor, etc. En el siguiente paso, se considera el sistema climático como una distribución multivariada que tiene aspectos marginales, temporales, espaciales e intervariables; aquí se involucran aspectos como la intensidad, la estacionalidad o la duración de los episodios extremos, la extensión espacial de un evento, entre otros. En el tercer paso, se seleccionan índices para cuantificar los aspectos considerados. Finalmente, se seleccionan medidas de desempeño apropiadas, como sesgos o puntajes de habilidad, para comparar los índices derivados de los datos del modelo con los de las observaciones (Maraun D. *et al.*, 2015b).

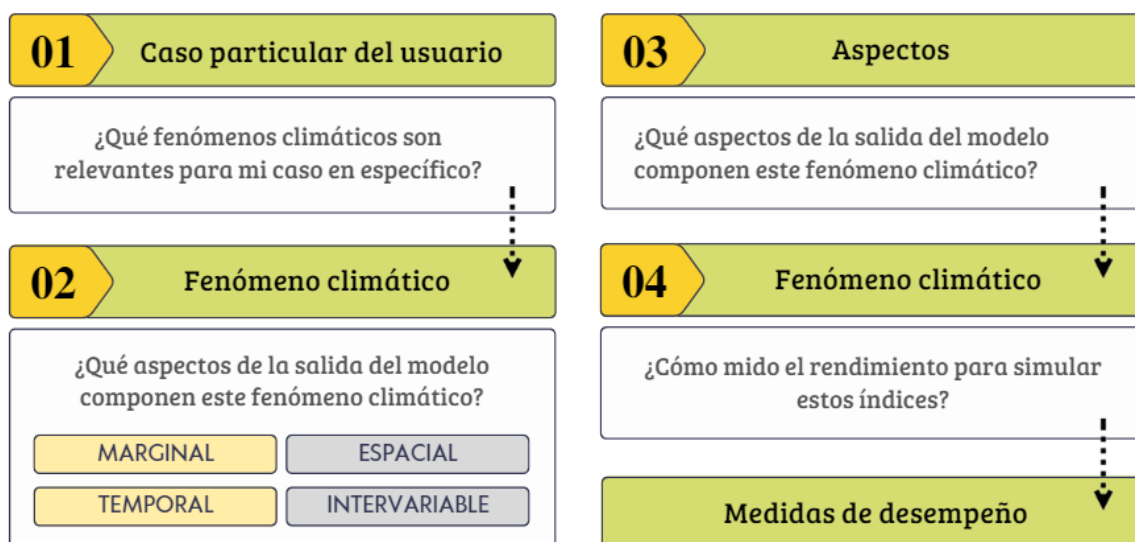


Figura 10. Esquematización del árbol de validación
FUENTE: Adaptado de Maraun D. *et al.*, 2015b.

La lista de índices actualizados y las medidas de rendimiento correspondientes están disponibles en el sitio web de VALUE². Siguiendo con esta metodología, los índices

2 www.value-cost.eu/indices

seleccionados en el presente informe se muestran en la Tabla 6.

Tabla 6: Métricas usadas para la validación

Descripción	Variable	Unidades
Bias (para la media)	Temperatura	°C
Bias (para el percentil 2)	Temperatura	°C
Bias (para el percentil 98)	Temperatura	°C
Error cuadrático medio	Temperatura	°C
Ratio de las desviaciones estandar	Temperatura	-
Correlación de pearson	Temperatura	-

FUENTE: Adaptado de Baño-Medina *et al.*, 2019.

2.10 TOPSIS

La Técnica de Orden de Preferencia por Similitud a la Solución Ideal (TOPSIS, por sus siglas en inglés), es un método de decisión multicriterio que se basa en el concepto de que la mejor alternativa debería estar a la menor distancia de la solución ideal y más alejada de la alternativa anti-ideal (Song *et al.*, 2021), esto lo discrimina mediante el cálculo de un índice para cada modelo (C_a); mientras más cerca este a uno es la mejor alternativa. De esta manera se puede seleccionar el modelo más adecuado con mayor robustes. La ecuación 1 muestra la fórmula utilizada para calcular el índice de similitud.

$$C_a = \frac{D_a^-}{D_a^- + D_a^+} \quad (1)$$

Donde:

Índice “ C_a ”, Calcula el grado de similitud a la solución ideal, mientras más cercano a 1 es la mejor alternativa. Si se acerca más a 0, entonces es más parecida a la solución anti ideal. FUENTE: (Song *et al.* 2021)

D_a^- : Solución anti-ideal

D_a^+ : Solución ideal

2.11 Reanálisis ERA-5

El reanálisis ERA-5 provee datos que cubre a todo el planeta de manera grillada con una resolución de 0.25 grados (30 km), usando 137 niveles de presión desde superficie hasta los 80 km de altura (Hersbach et al., 2020). Esta reanálisis combina datos modelados con observados de todo el mundo, asimismo completa la información faltante mediante las leyes de la física (ECMWF, 2018).

2.12 Controladores climáticos de Puno

Los controladores climáticos hacen referencia a factores meteorológicos, oceánicos y continentales que tienen influencia sobre un área en específico, para el Perú estos se han definido como un conjunto de sistemas sinópticos, patrones de circulación, corrientes oceánicas y cadenas montañosas que contribuyen a definir clima de nuestro país (Castro *et al.*, 2021).

El departamento de Puno se ubica en la región sur - este del Perú, limita por el norte con el departamento de Madre de Dios, por el sur con Tacna, por el sur-este con Bolivia, por el oeste con Moquegua, Arequipa y Cusco (Figura 11). Su territorio abarca 71 999 km², lo cual comprende aproximadamente el 6% del territorio nacional y lo posiciona como el quinto departamento más grande del Perú (BCRP, 2023). Puno posee una gran diversidad de ecosistemas, que van desde cumbres nevadas a valles tropicales, el 70% de su territorio está constituido por la altiplanicie del Collao y el 30 % restante lo constituyen la Cordillera de Carabaya y zona de selva hacia el límite con Madre de Dios (SENAMHI, 2013). Las unidades geográficas presentes en el departamento de Puno son las siguientes (GRP, 2013):

- Sierra, abarca el 76.9% de la superficie del departamento, con altitudes que varían entre 2 000 m.s.n.m (ladera oriental) a más de 5 500 m.s.n.m (cordillera occidental y oriental). El clima es frío y seco, con temperaturas entre 5 °C a 13 °C. Su fisiografía está determinada por la topografía, el clima, y su vocación productiva.
- Selva, abarca 23.1% de la superficie del departamento, con altitudes que varían entre 400 m.s.n.m a 2000 m.s.n.m. Se diferencia por tener una fisiografía accidentada, con colinas bajas y de llanura aluvial.

De acuerdo con lo observado en el Compendio Estadístico del Instituto Nacional de Defensa Civil (INDECI, 2021), los fenómenos naturales que más afectan al departamento de Puno

son: heladas, friajes, movimientos de masa (e.g., deslizamientos, caída de rocas, aludes, flujo de detritos o “huaycos”), incendios forestales, lluvias intensas, vientos fuertes y en menor medida las inundaciones; estos causan daños a las personas, viviendas e incluso pérdidas de hectáreas de cultivo. Debido a que se prevé un aumento en la frecuencia de estos fenómenos naturales debido a los efectos del cambio climático (IPCC, 2022), es importante mejorar la capacidad de adaptación de las poblaciones del departamento de Puno a fenómenos de origen natural.



Figura 11. Mapa del departamento de Puno

NOTA: ley n° 27795 - Quinta Disposición Transitoria y Final de la Ley de Demarcación y Organización Territorial: “en tanto se determina el saneamiento de los límites territoriales, conforme a la presente ley, las delimitaciones censales y/u otros relacionados con las circunscripciones existentes son de carácter referencial”.

FUENTE: INEI, 2014.

Debido a las condiciones orográficas y climáticas complejas presentes en el departamento de Puno, se diferencian un total de 18 tipos de climas, siendo los más predominantes los siguientes (Castro *et al.*, 2021):

- En la unidad geográfica selva (vertiente amazónica), ubicada al norte del departamento, predominan los climas lluviosos, de característica térmica cálida o templada y con humedad abundante durante todo el año. En ese sentido se tienen los climas: A(r)B' y A(r)A' y B(r)B'.
- En la unidad geográfica sierra, ubicada en el altiplano del centro y sur del departamento, predominan los climas semisecos, de característica térmica fría o semifrígida; como lo observado en los climas C(o,i)D', C(o,i)C', C(i)C' y C(i)D'. Al sur este de las provincias del Collao el clima es aún más frío y seco (C(i)E'). En la región influenciada por el lago Titicaca se presenta un clima lluvioso, frío y deficiente de humedad en otoño e invierno (B(o,i)C'). Además, al sur de la provincia de Carabaya y centro de la provincia de Sandías se observan glaciares en las cumbres. Cabe resaltar que al sur del departamento se ubican climas lluviosos y con humedad abundante; sin embargo, estos ocupan las menores áreas, y se mantiene la característica térmica fría.

De acuerdo con el SENAMHI (2013), los controladores climáticos de la región del departamento de Puno son los siguientes: (i) Alta de Bolivia, (ii) Frentes fríos, (iii) Anticiclón del Atlántico Sur, (iv) Anticiclón del Atlántico Norte y (v) lago Titicaca. A continuación, se presenta una descripción detallada de cada uno.

2.12.1 Alta de Bolivia

Para esta región, uno de los controladores climáticos de altos niveles más importante es la Alta de Bolivia (AB), que es un sistema de circulación antihoraria ubicada en la tropósfera superior. Su formación se debe al calor sensible, proveniente del calentamiento solar del altiplano peruano, boliviano y chileno, además de la gran cantidad de calor liberado sobre la selva media y alta por el cambio de fase del vapor de agua (Castro *et al.*, 2021).

La Alta de Bolivia no tiene una posición totalmente fija, sino que presenta ligeros movimientos en función de las características meteorológicas reinantes en determinado momento, y dependiendo de ello tendrá cierto efecto sobre diferentes zonas; es así que cuando el núcleo de este sistema se encuentra ubicado en el centro del territorio boliviano, la dinámica de este induce lluvia en la sierra y selva (Maldonado Calani, 2020). Esto se ve reflejado tanto en el territorio boliviano como en el peruano a lo largo del verano austral

(periodo húmedo); mientras que en el periodo seco (de abril a agosto) el sistema no se encuentra presente (Castro *et al.*, 2021).

En la Figura 12 se muestra la distribución espacial de la Alta de Bolivia en la alta atmósfera, esta se encuentra representada por medio de líneas de corriente en el nivel isobárico de 200 hPa.

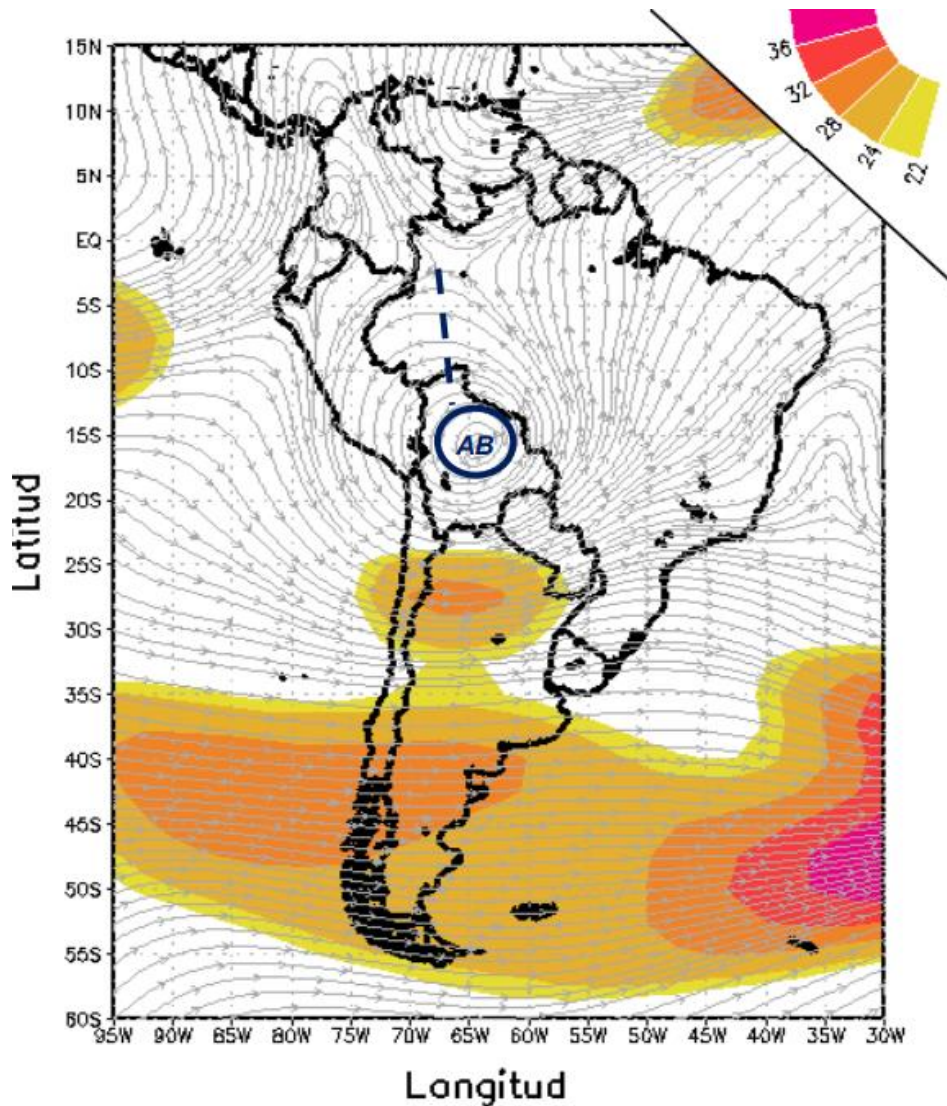


Figura 12. Distribución del Alta de Bolivia para el mes de enero
FUENTE: Maldonado Calani, 2020.

2.11.2 Frentes fríos

Los frentes son las fronteras que separan masas de aire con distintas características de presión, temperatura, volumen, etc; suelen estar asociados a sistemas de baja presión y dependiendo de las masas de aire que separan se clasifican como frente cálido o frío (UCAR, 2021). La interacción entre las masas de aire en un frente genera el levantamiento de la masa

de aire cálida y húmeda, lo cual origina extensas bandas nubosas que se divisan desde el Atlántico hasta la selva norte de Bolivia (Castro *et al.*, 2021). Este sistema se presenta de manera más frecuente en los meses de invierno y promueve el ingreso de humedad en la selva de Puno, así como los friajes; ya que la masa de aire frío al ser más densa se queda en superficie e interacciona con la población y los cultivos (SENAMHI, 2013). En la Tabla 7 se muestran todos los tipos de frentes y en la Figura 13 su representación cartográfica.




Figura 13. Representación de un frente en la cartografía meteorológica
FUENTE: UCAR, 2021.

Tabla 7: Tipos de frentes y su representación cartográfica

Frentes	Descripción
Frentes fríos	Representados por triángulos azules que indican la dirección del viento del movimiento de la masa de aire frío.
Frentes cálidos	Representados por semicírculos rojos que indican la dirección del viento del movimiento de la masa de aire cálido.
Frentes ocluidos	Se forma cuando un frente frío alcanza a un frente cálido; en estos límites frontales el aire cálido está separado del centro de la baja presión. Representados por líneas sólidas de color morado.
Frentes estacionarios	Se forma cuando un frente cálido y frío se dejan de mover, esto genera diferencias notables en la temperatura y los vientos en pequeñas distancias. Representados por semicírculos rojos y triángulos azules.

FUENTE: UCAR, 2017.

2.11.3 Anticiclones del atlántico sur y norte

El flujo tridimensional del aire en la tropósfera es representado por el modelo de Circulación General de la Atmósfera (CGA), que considera las principales corrientes ascendentes y descendentes, los vientos dominantes y las células de circulación que definen la dinámica atmosférica (Viñas, 2019). En la Figura 14 se muestra el CGA de tres células (Hadley, Ferrel y Polar) para un planeta con continentes. La convergencia de los vientos alisios configura la Zona de Convergencia Intertropical (ITCZ, por sus siglas en inglés), por el principio de conservación de la masa esto genera divergencia en altura que moviliza el viento a zonas subtropicales, en donde predomina la subsidencia y dan como resultado los grandes anticiclones subtropicales (Laing & Evans, 2016).

El Anticiclón del Atlántico Sur (AAS) y Norte (AAN) deben su nombre debido a que la ubicación de sus centros se encuentra en el Atlántico Sur y Norte, respectivamente. Ambos sistemas transportan gran cantidad de humedad hacia la cuenca amazónica o al altiplano, la cual al ser transportada verticalmente genera nubes convectivas u orográficas que ocasionan lluvias (SENAMHI, 2013).




Figura 14. Modelo de CGA para un planeta con continentes

NOTA: Los vientos en superficie asociados a la Célula de Hadley son los Alisios, a la Célula de Ferrel son los Vientos del Oeste y para la Célula Polar se les conoce como los Vientos del Este. A los 90° de latitud se tienen las Altas Polares, en las que predomina el tiempo atmosférico apacible.

FUENTE: Laing & Evans, 2016.

2.11.4 Lago Titicaca

El lago navegable más alto del mundo, ubicado a 3800 m.s.n.m y con una profundidad de 280 m, es el lago Titicaca; este se encuentra en el altiplano andino, en la parte central de la meseta del Collao y genera una gran cantidad de ecosistemas a su alrededor (SENAMHI, 2013). Este es un controlador climático importante para el departamento de Puno; sin embargo, en los últimos años se observa un descenso continuo del nivel del agua en el lago debido a los sucesivos eventos climáticos La Niña y El Niño, que generan escasez de lluvias y altas temperaturas, respectivamente; contribuyendo a la evaporación (Gestión, 2023). Esta disminución del nivel de agua afecta a las actividades económicas de la población del departamento de Puno (e.g., pesca, agricultura, turismo) (Guy & Rebaza, 2023). En la Figura 15 se observa el proceso de secado del lago Titicaca.

Año 2023



Año 1969




Figura 15. Secado progresivo del lago Titicaca

FUENTE: LA IMAGEN DE 1969 ES DEL US GEOLOGICAL SERVICE Y LA DEL 2023 DEL LANDSAT.

III. METODOLOGÍA

3.1 Datos y área de estudio

3.1.1 Variables predictoras

Para la representación de las condiciones atmosféricas a gran escala se usaron los datos del reanálisis ERA5, ya que provee estimaciones a resolución horaria y con un grillado de 27 km de una gran cantidad de variables atmosféricas, terrestres y oceánicas (ECMWF, 2022). Estos datos pueden ser descargados mediante el portal “*Copernicus Climate Data Store*” (CDS)³.

Para la selección de las variables predictoras, se utilizó como base los controladores climáticos del departamento de Puno. En la Tabla 8 se muestran las variables asociadas a sus respectivos controladores climáticos. Es importante resaltar que el dominio seleccionado no incluyó los centros de los anticiclones del atlántico sur y norte, ya que se encuentran alejados del departamento de Puno y su influencia está representada como el transporte de humedad específica por el viento zonal y meridional en niveles bajos. Debido a que el 76.9% de la superficie de Puno abarca altitudes entre 2000 m.s.n.m y 5500 m.s.n.m (GRP, 2013), se consideró el nivel isobárico de 850 hPa como superficial, 700 hPa como niveles bajos, 200 hPa y 300 hPa como niveles altos.

³ <https://cds.climate.copernicus.eu/cdsapp#!/search?text=ERA5%20back%20extension&type=dataset>

Tabla 8: Lista de variables por controlador climático

Niveles	Variables	Controlador climático representado
Altos (200 y 300 hPa)	geopotencial, viento zonal y meridional	Alta de Bolivia
Bajos (700 hPa)	Humedad específica, temperatura, viento zonal y meridional	Frentes fríos, Anticiclón del atlántico sur y norte
Superficie (850 hPa)	Temperatura del aire, altura geopotencial, humedad específica, viento zonal y meridional	Lago Titicaca y Alta migratoria *

NOTA: Aunque el alta migratoria no figure como uno de los controladores climáticos de puno, se ha demostrado que se encuentra relacionada a la ocurrencia de friajes en la región. Se representó mediante la altura geopotencial en el nivel de 850 hPa.

FUENTE: Avalos Roldán & Quispe Gutiérrez, 2000.

El dominio de los predictores se definió considerando que puedan abarcar de manera representativa la influencia de los controladores climáticos del departamento de Puno, lo cual incluye: aporte de humedad proveniente del AAN hacia la cuenca amazónica, el núcleo de la Alta de Bolivia, aporte de humedad proveniente del AAS hacia el altiplano, la zona correspondiente al origen del alta migratoria, el lago Titicaca, masa de aire frío en superficie asociada a los frentes fríos. De esta manera, el dominio de las variables predictoras comprende entre las latitudes 40°S – 0° y entre las longitudes 80°W – 40°W. En las Figuras 16, 17 y 18, se muestra la climatología, calculada como el promedio en el periodo de 1981 – 2005, de las variables predictoras utilizadas en el presente estudio.

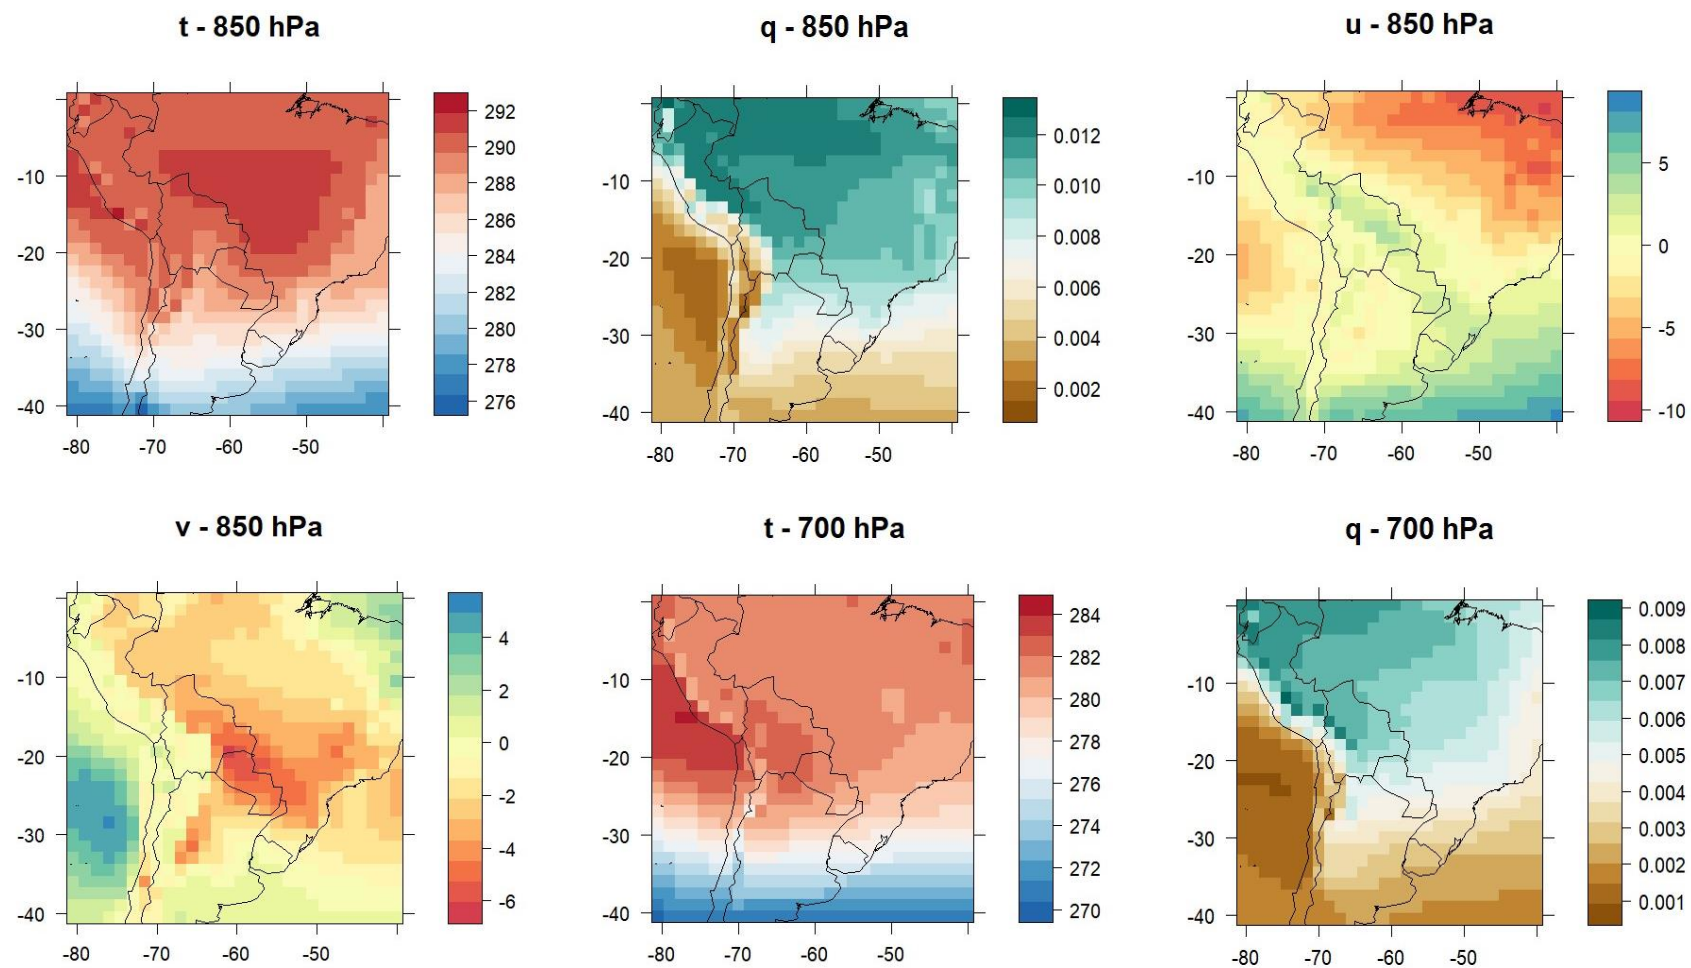


Figura 16. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 1
 NOTA: CLIMATOLOGÍA DE: u = VIENTO ZONAL (m/s), v = VIENTO MERIDIONAL (m/s) y z = GEOPOTENCIAL (m²/s²).

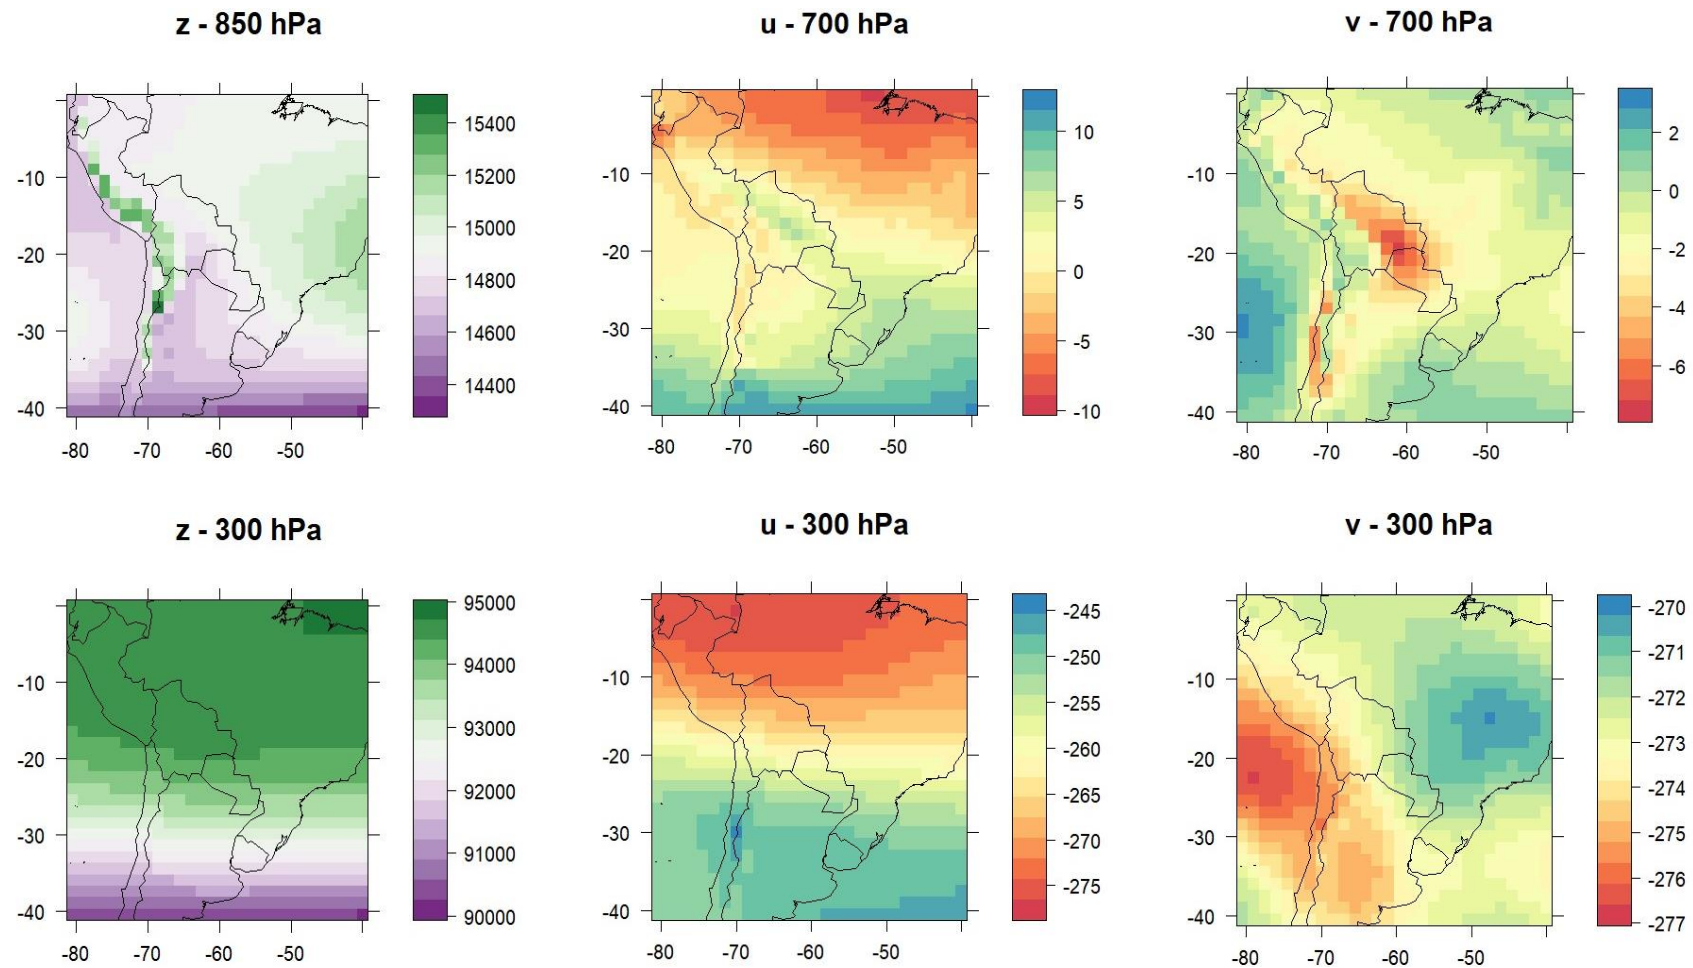


Figura 17. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 2
 NOTA: CLIMATOLOGÍA DE: u = VIENTO ZONAL (m/s), v = VIENTO MERIDIONAL (m/s) y z = GEOPOTENCIAL (m²/s²).

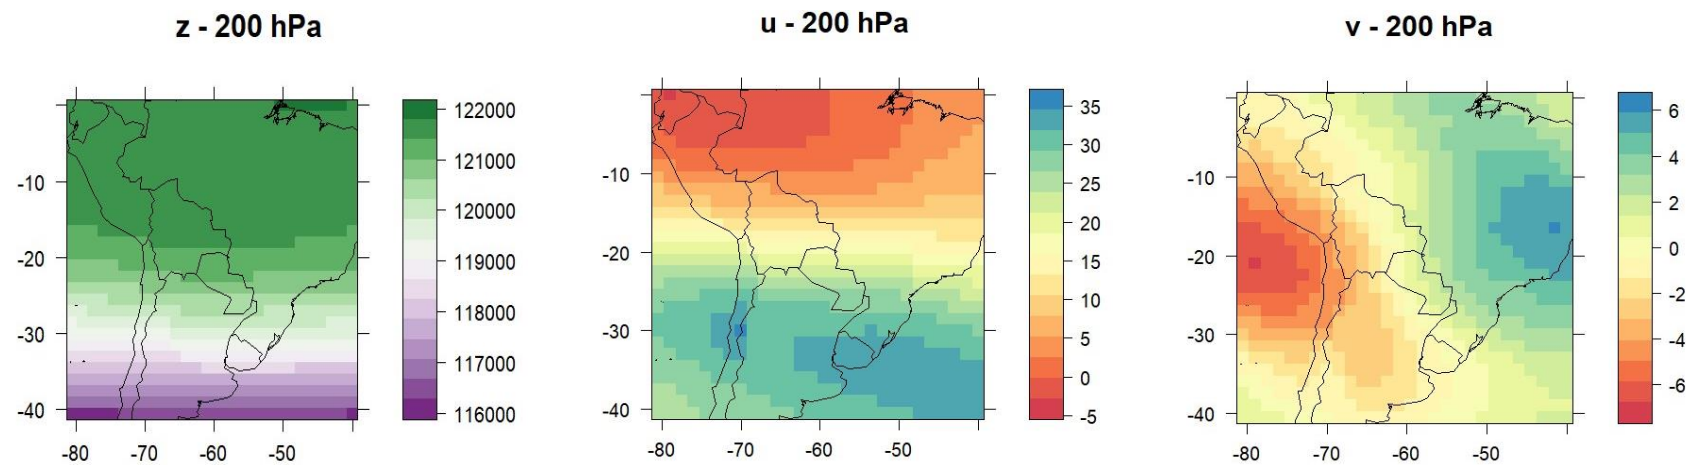


Figura 18. Climatología del periodo de entrenamiento de las variables predictoras por nivel isobárico del ERA5 – Grupo 3
 NOTA: CLIMATOLOGÍA DE: u = VIENTO ZONAL (m/s), v = VIENTO MERIDIONAL (m/s) y z = GEOPOTENCIAL (m^2/s^2).

3.1.2 Variables predictandos

Los predictandos locales son la temperatura máxima y mínima diaria a una resolución de 10 km para el departamento de Puno. Para representarlos se recurrió a la utilización de datos observados provenientes de estaciones y datos grillados.

En cuanto a los datos grillados, se utilizará información del producto PISCO (“*Peruvian Interpolation data of the SENAMHI’s Climatological and hydrological Observations*”), que están generados a 10 km de resolución espacial y para el periodo 1981 – 2016 en todo el Perú. Para la generación de PISCO se utilizó una combinación de datos observados e imágenes satelitales; los datos de las estaciones meteorológicas del SENAMHI fueron sometidos a control de calidad, imputación y homogenización (Huerta *et al.*, 2018).

En cuanto a los datos observados, se utilizó información de estaciones meteorológicas bajo administración del SENAMHI para verificar los resultados obtenidos por las proyecciones. De esta manera se dispuso de dos (02) filtros de validación para verificar las salidas de los modelos generados.

El dominio de los predictandos se definió de tal forma que contenga al departamento de Puno, es decir entre las latitudes 17.35°S -13.05°S y entre las longitudes 71.15°W - 68.05°W. Esto se muestra en la Figura 19.

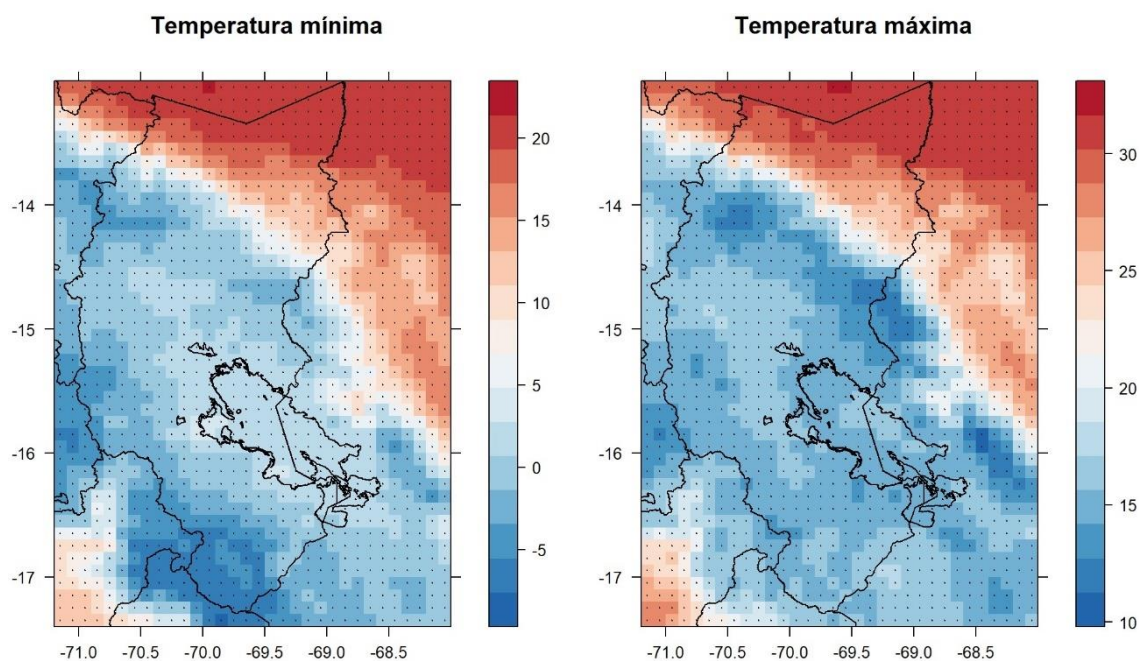


Figura 19. Dominio de los predictandos del producto PISCO
NOTA: Temperatura máxima y mínima en grados celsius (°C).

El proceso de regionalización estadística abarca 4 fases: preprocesamiento, entrenamiento, validación y generación de las proyecciones futuras. Estas son descritas a continuación y se muestran esquemáticamente en la Figura 20.

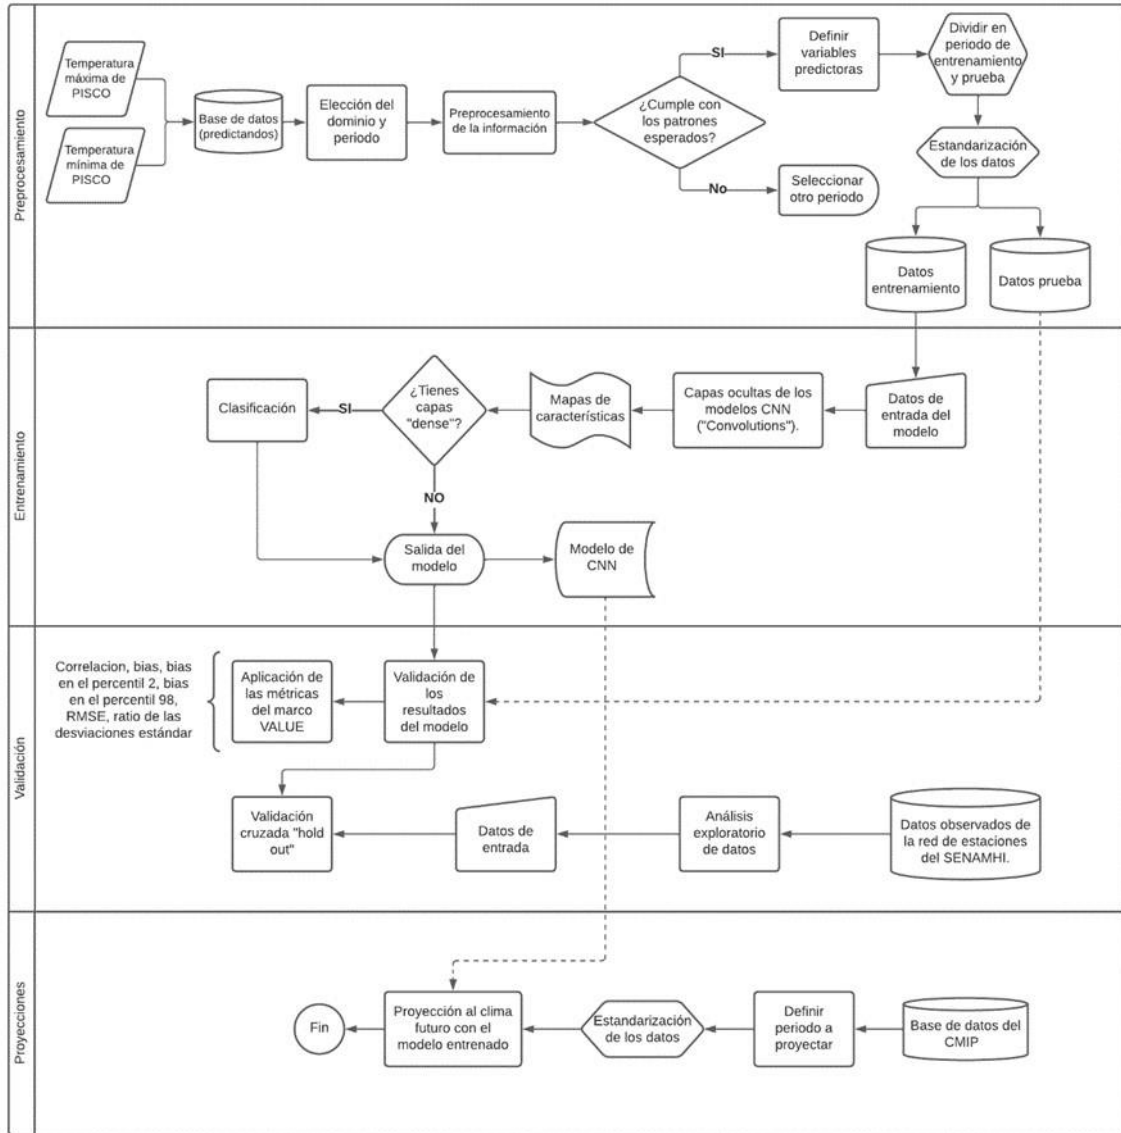


Figura 20. Flujograma del proceso de regionalización estadística de escenarios climáticos

3.2 Preprocesamiento

Consiste en seleccionar las variables locales de interés (predictandos) y elegir el dominio y periodo de estudio. Luego, se escogen los predictores más adecuados que tengan influencia en las variables que se pretende pronosticar. Esta etapa contempla la elaboración de bases de datos y búsqueda de referencias bibliográficas.

El método utilizado para regionalización estadística son las “*Convolutional Neural Network*” (CNN) y los detalles de su arquitectura se muestran en la Tabla 9. Además, se ejecutó la técnica de regresión lineal generalizada con 4 grillas cercanas (GLM4), para poder comparar los resultados con estudios anteriores.

Tabla 9: Lista de modelos usados en el estudio

Modelo	Capas				Tamaño de la grilla (°)	Descripción
	Entrada	Con ¹	Dense	Salida		
GLM4	20x4	-	-	3	1408	Modelo de regresión lineal generalizada con 4 grillas cercanas
CNN-LM	20	50-25-1	-	3	1408	CNN con función de activación lineal
CNN1	20	50-25-1	-	3	1408	CNN con función de activación no lineal con 1 mapa de características en la última capa.
CNN10	20	50-25-10	-	3	1408	CNN con función de activación no lineal con 10 mapas de características en la última capa
CNN-PR	20	10-25-50	-	3	1408	CNN con número creciente de mapas de características
CNNdense	20	50-25-10	50-50	3	1408	Usa modelos complejos de CNN

NOTA:

¹Con = CAPAS “CONVOLUCIONALES”

3.3 Entrenamiento

Primero se introducen los predictores a gran escala como datos de entrada de los modelos de aprendizaje automático (CNN), estos procesan la información siguiendo su estructura de capas ocultas y “*convolutional*” para generar los mapas de características. Después, son clasificados y se generan los valores proyectados de los predictandos. Los datos del ERA-5 y PISCO, son los *reanalysis* empleados en el presente estudio, el primero como predictor y el segundo como predictando. El periodo utilizado para la fase de entrenamiento comprende entre los años 1981 al 2005 y para la fase de validación se reservó el periodo de 2006 al 2010.

Para los métodos que emplean la técnica CNN, uno de los modelos usa una función de activación lineal (CNN-LM) y genera relaciones lineales entre las variables, de similar forma que el GLM4. Los otros tienen funciones de activación no lineales (ReLU) y por tanto generan relaciones no lineales entre los datos. Todos los modelos de aprendizaje profundo usados tienen 3 capas ocultas con un número descendente de mapas de características (50-25-10, capas “convolucionales”, para CNN10; y 50-25-1, para CNN-LM, CNN1 y CNN dense), a excepción del CNN-PR. En este último, los mapas de características aumentan (10-25-50); lo cual es la aproximación que se suele usar en visión por computador para reconocimiento de patrones (Bedia *et al.*, 2019). Cada una de estas configuraciones se utilizaron para probar la influencia de los diferentes elementos de la arquitectura de las CNN en su capacidad de aprender características espaciales de complejidad creciente de la data de una manera jerárquica.

El procesamiento de la información y la regionalización estadística se elaboraron mediante el uso de lenguaje de programación R (R Core Team, 2022) y el entorno de trabajo Rstudio (RStudio Team, 2020). Los paquetes que se usaron fueron, principalmente, los referidos al “CLIMATE 4R bundle” (Iturbide *et al.*, 2019), que incluye al “loadR”, “transformR”, “downscaleR”, “visualizeR”, entre otros. Estos permiten acceso a bases de datos climáticas, procesamiento de estas y su visualización.

3.3 Validación

En este trabajo se hicieron 2 validaciones: la primera mediante las métricas del marco de validación VALUE, la cual estaba aplicada a los mismos datos de PISCO; mientras que en la segunda validación tipo “*hold out*” se compararon los valores proyectados con los datos

de las estaciones bajo administración del SENAMHI. Ambas están basadas en la metodología de validación cruzada.

De acuerdo con el método de validación cruzada se dividió la data en el periodo de entrenamiento (1981-2005) y prueba (2006-2010). En el primero se generaron varios modelos para que obtengan relaciones estadísticas lineales y no lineales entre las variables a larga escala (predictores) y las variables locales de interés (predictandos). En la Tabla 10, se muestran las métricas de VALUE usadas en el presente estudio.

Tabla 10: Métricas usadas para la validación VALUE

Descripción	Variable	Unidades
Bias (para la media)	Temperatura	°C
Bias (para el percentil 2)	Temperatura	°C
Bias (para el percentil 98)	Temperatura	°C
Error cuadrático medio	Temperatura	°C
Ratio de las desviaciones estandar	Temperatura	-
Correlación de pearson	Temperatura	-

FUENTE: (Baño-Medina *et al.*, 2019)

Para la validación *hold out* se compararon los datos predichos por el modelo con los registros de las estaciones bajo administración del Servicio Nacional de Meteorología e Hidrología (SENAMHI). Las estaciones usadas en el presente estudio se muestran en la Tabla 11 y en la Figura 21 se observa su ubicación espacial. La validación de las temperaturas máximas y mínimas de las estaciones se describe en el Anexo A.

Tabla 11: Estaciones bajo administración del SENAMHI usadas para la validación *hold out*

Estación	Código	Coordenadas geográficas		Altitud (msnm)	
		Latitud ¹	Longitud ¹		
Crucero	114058	-14.364194	-70.025917	4128	
Huaraya Moho	115038	-15.388097	-69.484192	3836	
Isla Suana	116009	-16.329917	-68.850333	3840	
Lampa	100081	-15.361083	-70.374167	3866	
Mazo Cruz	116026	-16.738889	-69.715444	3980	
Progreso	114040	-14.671694	-70.367806	3925	
Pucara	115046	-15.045667	-70.366639	3877	

¹ La latitud negativa es indicativo del hemisferio sur y la longitud negativa es indicativo del oeste del meridiano de Greenwich.

Finalmente, para una selección objetiva del mejor modelo se utilizará el método de decisión multicriterio TOPSIS, que tiene la capacidad de resumir todos los indicadores estadísticos del marco de validación VALUE de la Tabla 10 en un solo índice (C_a), lo que facilita la determinación del modelo que mejor representa el comportamiento y la variabilidad de los predictandos.

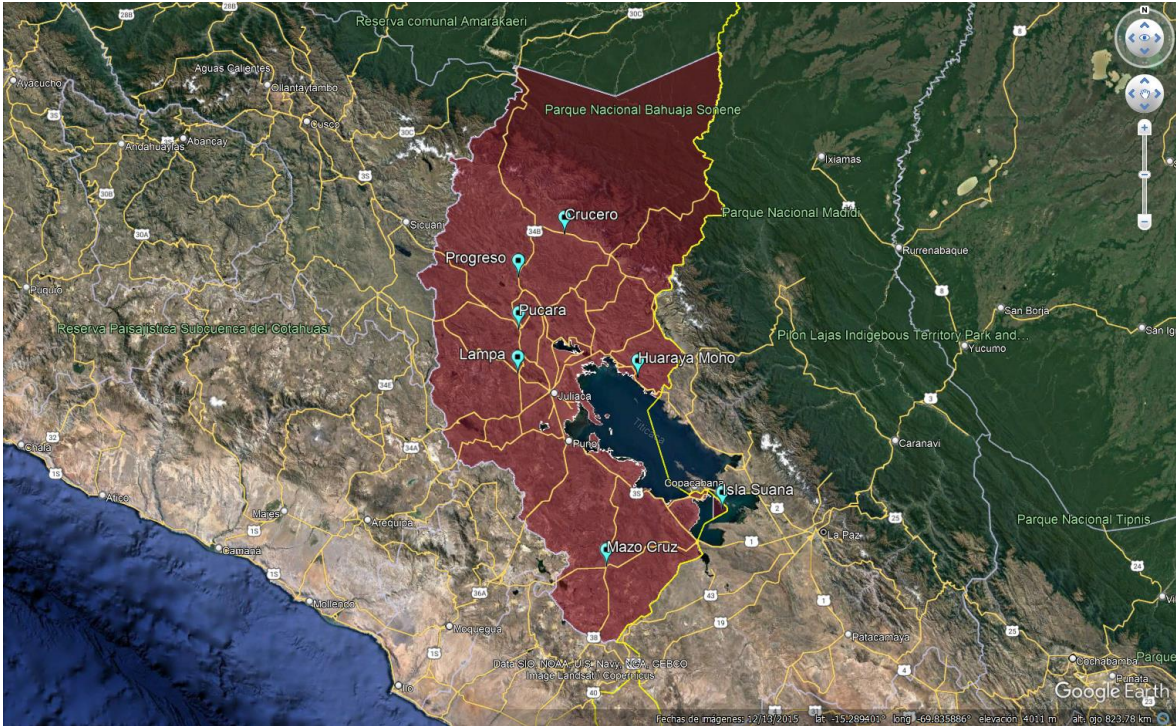


Figura 21. Ubicación espacial de las estaciones del SENAMHI empleadas

3.4 Generación de proyecciones

Una vez entrenado y validado los modelos de aprendizaje profundo, se procede a la regionalización de escenarios futuros del CMIP5. En este caso se utilizaron las proyecciones del modelo CanESM2, particularmente el experimento RCP8.5, el cual tiene un mayor forzamiento radiativo y representa un escenario más desfavorable. Se eligió el miembro del ensamble principal denotado por r1i1p1. En esta sección de generación de proyecciones, se incluyeron únicamente los modelos que tuvieron mejores resultados de acuerdo con la metodología TOPSIS.

Además, se realizó un análisis con el método Theil-Sen para determinar la tendencia de los registros diarios de la temperatura máxima y mínima en periodo del 2021 al 2040. Es preciso indicar que las ventajas del método Theil-Sen radican en que este tiende a producir intervalos de confianza precisos, incluso con datos que no tienen una distribución normal, y presenta heterocedasticidad (i.e., varianza de error no constante); además, es resistente a valores extremos (Carslaw, 2019).

IV. RESULTADOS Y DISCUSIÓN

4.1 Análisis de los predictandos

En la Tabla 12 se observan los estadísticos de los predictandos para el periodo de entrenamiento y de prueba. En el Figura 22 se muestra la climatología de la temperatura máxima para el periodo de entrenamiento y prueba; en el Figura 23 se muestra lo mismo para la temperatura mínima.

Tabla 12: Estadísticos de los predictandos del dominio

Periodo	Predictando	Promedio	Mediana	Máximo	Mínimo
Entrenamiento (1981 - 2005)	Temperatura máxima (°C)	19.54	16.99	39.93	1.10
	Temperatura mínima (°C)	4.87	2.98	26.49	-23.87
Prueba (2006 - 2010)	Temperatura máxima (°C)	20.19	17.63	39.09	2.93
	Temperatura mínima (°C)	4.98	3.12	25.13	-22.22

NOTA: ELABORADO EN BASE A LOS DATOS DEL PRODUCTO PISCO DEL SENAMHI.

Al comparar los periodos de entrenamiento (1981 - 2005) y prueba (2006 - 2010) se observa que la climatología de los predictandos del periodo de prueba es superior a la del periodo de entrenamiento en 0.65 °C para la temperatura máxima y en 0.11 °C para la temperatura mínima. De manera similar, en el percentil 2 se tiene que la climatología del periodo de prueba es superior en 0.82 °C para la temperatura máxima y en 0.35 °C para la temperatura mínima. En el percentil 98 para la temperatura máxima el periodo de prueba es mayor en 0.46 °C y para la temperatura mínima en 0.18 °C. Por tanto, se evidencia una mayor tasa de calentamiento para la temperatura máxima, usualmente diurna, en comparación con la temperatura mínima, usualmente nocturna. Lo cual está asociado a regiones secas (Gonzales, 2021), esto coincide con el clima frío y seco presente en el 76.9% de la superficie del departamento de Puno (GRP, 2013).

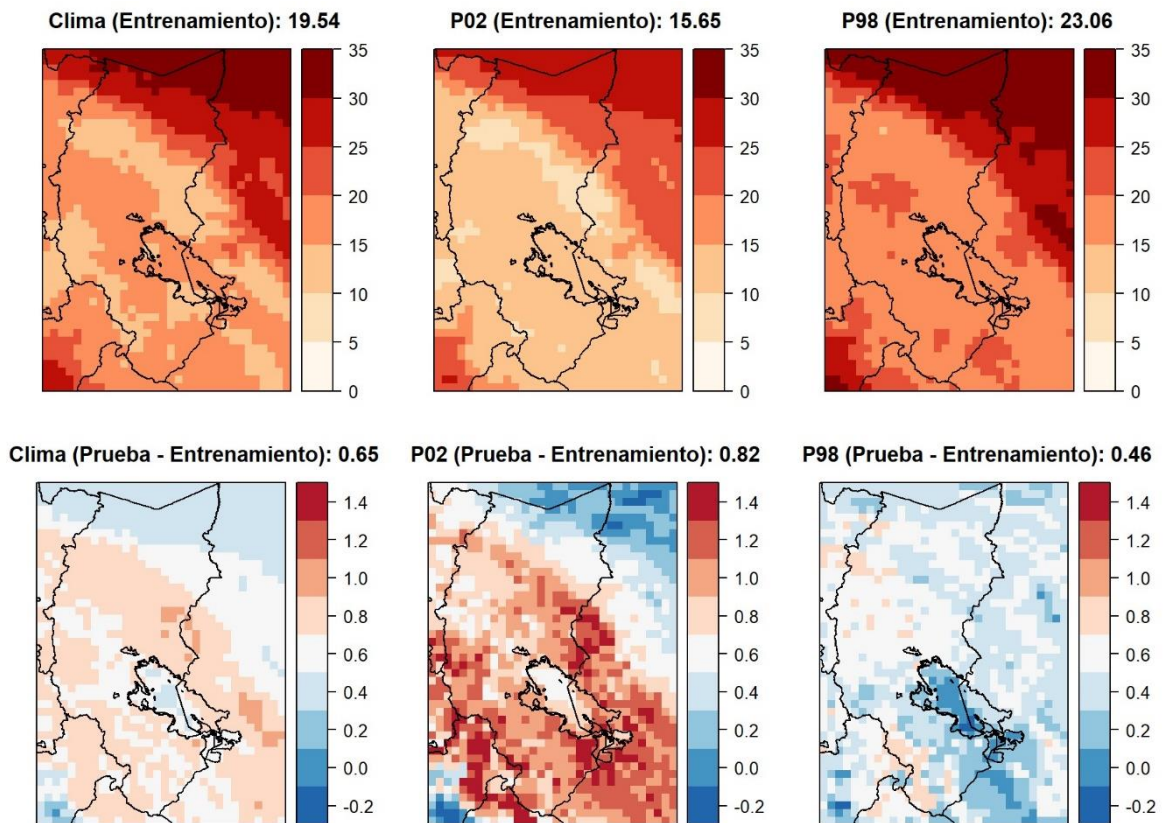


Figura 22. Comparación entre el periodo de entrenamiento y prueba para la temperatura máxima

NOTAS:

1. Periodo de entrenamiento comprende entre 1981 – 2005.
2. Periodo de prueba comprende entre 2006 – 2010.
3. P02: Percentil 2 y P98: Percentil 98.
4. El número ubicado en la parte superior derecha de cada gráfico hace referencia al promedio de todas las grillas del dominio.

FUENTE: Elaborado en base a los datos del producto Pisco del SENAMHI.

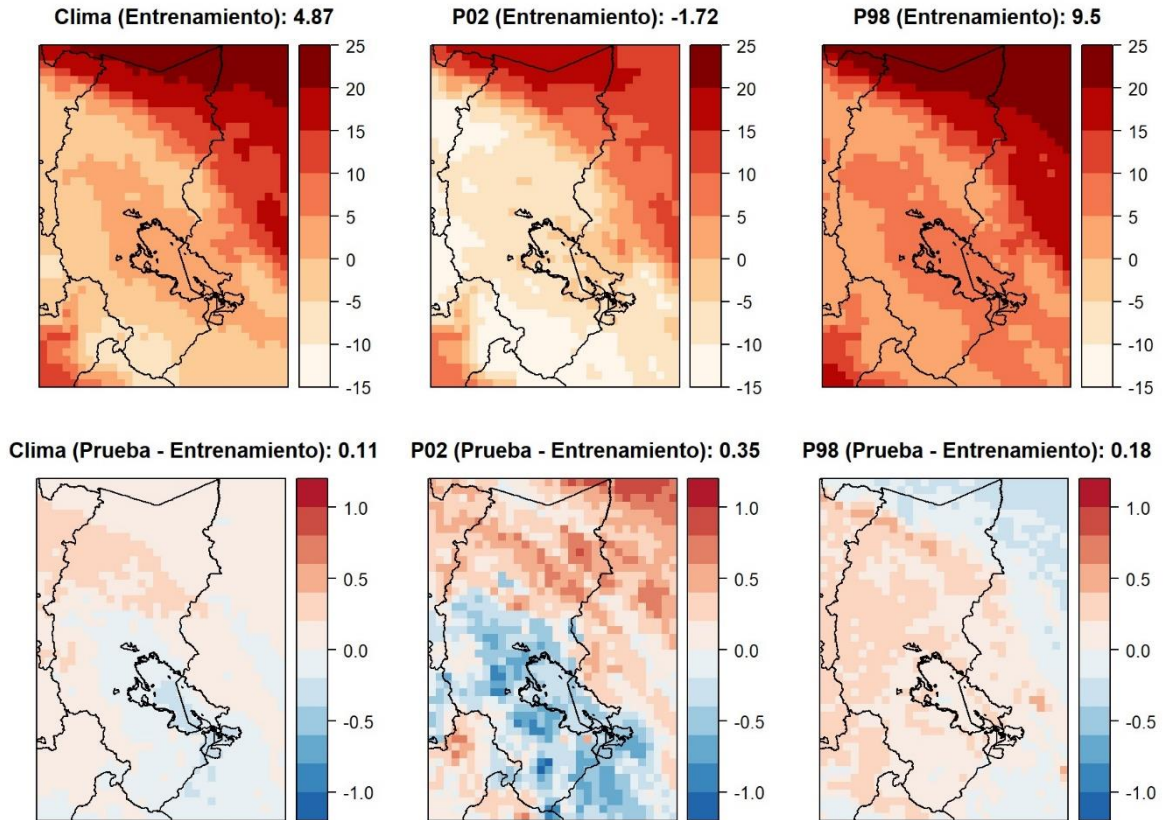


Figura 23. Comparación entre el periodo de entrenamiento y prueba para la temperatura mínima

NOTAS:

1. Periodo de entrenamiento comprende entre 1981 – 2005.
2. Periodo de prueba comprende entre 2006 – 2010.
3. P02: Percentil 2 y p98: Percentil 98.
4. El número ubicado en la parte superior derecha de cada gráfico hace referencia al promedio de todas las grillas del dominio.

FUENTE: elaborado en base a los datos del producto pisco del SENAMHI.

Los resultados de los modelos de aprendizaje profundo (CNN) y del modelo de regresión lineal generalizada (glm) se describen en las siguientes secciones para los predictandos analizados, que son la temperatura máxima y mínima.

4.2 Validación VALUE

4.2.1 Temperatura máxima

Los resultados obtenidos para la temperatura máxima se muestran como diagramas de cajas para cada método en el Figura 24. En el diagrama de cajas se evidencia que los modelos de aprendizaje profundo tienen mejores resultados que el modelo de regresión lineal generalizada. Es decir, menores RMSE, Bias más cercanos a cero, sobre todo en el percentil

98 lo cual es importante para la temperatura máxima, mayores correlaciones y ratios de la desviación estándar más realísticos.

Para el modelo CNN-LM se tiene que el Bias y el Bias en el percentil 98 poseen la mediana próxima a cero, lo cual indica un error medio bajo. La mediana del Bias en el percentil 2 se encuentra por encima de 0.4°C para todos los modelos, esto indica una sobreestimación en los valores mínimos. La ratio de la desviación estándar compara la medida de dispersión de los datos del periodo de entrenamiento y de prueba; para este estadístico se observa que el modelo CNN-PR tiene la mediana más alta, por tanto, es en el que más se asemeja la dispersión de los datos entre el periodo de entrenamiento y prueba; el resto de los modelos de aprendizaje profundo tienen ratios de desviación estándar superiores a 0.7. La mediana de la ratio de la desviación estándar para el modelo GLM4 es la más baja; por tanto, es el modelo en el que menos se asemeja la dispersión de los datos entre el periodo de entrenamiento y prueba.

Aunque existe una diferencia marcada entre los resultados de los modelos de aprendizaje profundo (CNN) al compararlos con el método de regresión lineal, no se evidencia una diferencia muy notoria entre los mismos modelos CNN. Para determinar el mejor de estos se recurrió al método de decisión multicriterio TOPSIS (Tabla 13).

Del análisis TOPSIS se evidencia claramente que el modelo CNN-LM es el que simula mejor los datos del periodo de prueba, ya que tiene el Bias más bajo, la correlación más alta y menor RMSE. El modelo GLM4, tiene un índice C_a de cero, esto indica que se trata de la alternativa anti ideal, es decir el modelo con los más altos Bias, correlación más alta y mayor RMSE.

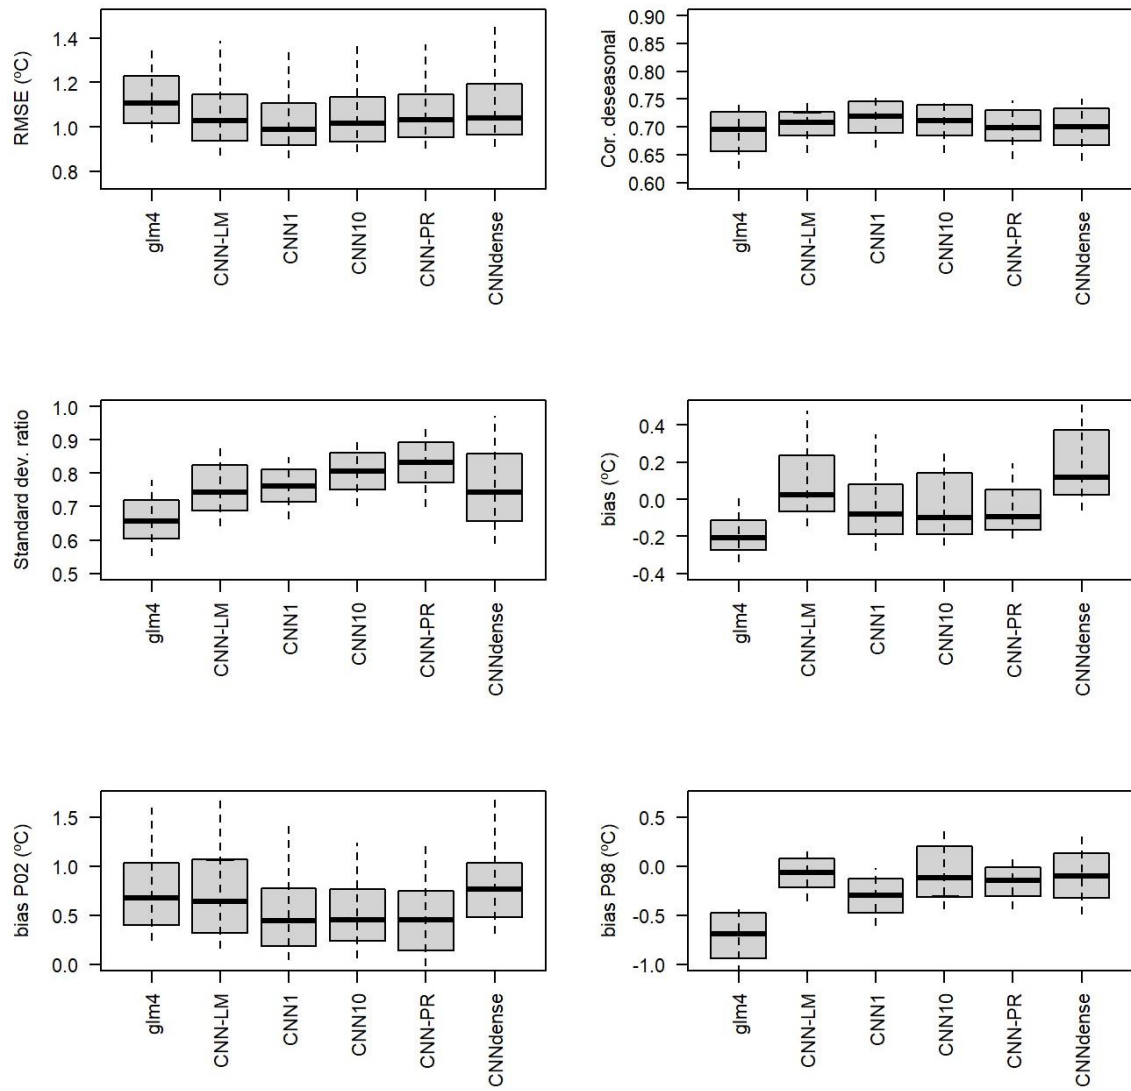


Figura 24. Comparación de los métodos de regionalización estadística para la temperatura máxima

Tabla 13: Análisis TOPSIS para temperatura máxima

Modelos	Matriz de Decisión			Modelos	Matriz de Decisión Normalizada Ponderada			Distancia a la AI (D_a^+)	Distancia a la AAI (D_a^-)	C_a
	R	BIAS	RMSE		R	BIAS	RMSE			
	Max	Min	Min		Max	Min	Min			
GLM4	0.69	0.21	1.11	GLM4	0.13	0.24	0.15	0.21	0.00	0.00
CNN-LM	0.71	0.02	1.03	CNN-LM	0.14	0.03	0.14	0.01	0.21	0.97
CNN1	0.72	0.08	0.99	CNN1	0.14	0.09	0.13	0.07	0.15	0.69
CNN10	0.71	0.10	1.02	CNN10	0.14	0.11	0.13	0.09	0.13	0.60
CNN-PR	0.70	0.10	1.03	CNN-PR	0.13	0.11	0.14	0.08	0.13	0.60
CNNdense	0.70	0.12	1.04	CNNdense	0.14	0.14	0.14	0.11	0.10	0.47
Peso	0.33	0.33	0.33	Alternativa Ideal (AI)	0.14	0.03	0.13	-	-	-
Norma	1.73	0.29	2.54	Alternativa Anti - Ideal (AAI)	0.13	0.24	0.15	-	-	-

NOTA: PARA REPRESENTAR EL BIAS, RMSE Y R SE CONSIDERÓ LA MEDIANA EN VALOR ABSOLUTO.

LEYENDA:

MEJOR MODELO DE ACUERDO CON LA METODOLOGÍA TOPSIS

En el Figura 25 se muestra la comparación espacial entre los métodos de regionalización estadística para la temperatura máxima, solo se realizó este análisis para los modelos con el índice Ca, del análisis TOPSIS, más alto. Para los modelos CNN-LM, CNN1 y CNN10, se evidencian mayores correlaciones para las zonas sur oeste y norte central del departamento de Puno. Además, las ubicaciones próximas al Lago Titicaca tienen correlaciones bajas. En la región altiplánica central y al sur del departamento de Puno, predomina la subestimación de las predicciones para todos los modelos CNN y al norte, en la unidad geográfica selva, predominan las sobreestimaciones. En cuanto al Bias en el percentil 98 para los modelos CNN1 y CNN-LM, se observa una predominancia de las sobreestimaciones en las zonas sur y norte del departamento de Puno; para la zona central predominan las subestimaciones. El modelo CNN10 presenta el mismo comportamiento descrito previamente para el Bias y el Bias en el percentil 98. En cuanto al RMSE, se observa que los mayores valores se encuentran al norte del departamento; mientras que al sur y centro los menores. En el Figura 25 se evidencia que se obtuvo temperatura máxima a 2 metros de la superficie con una resolución espacial de 10 km, mejorando de esta forma la resolución inicial del ERA-5 de 27 km (0.25°).

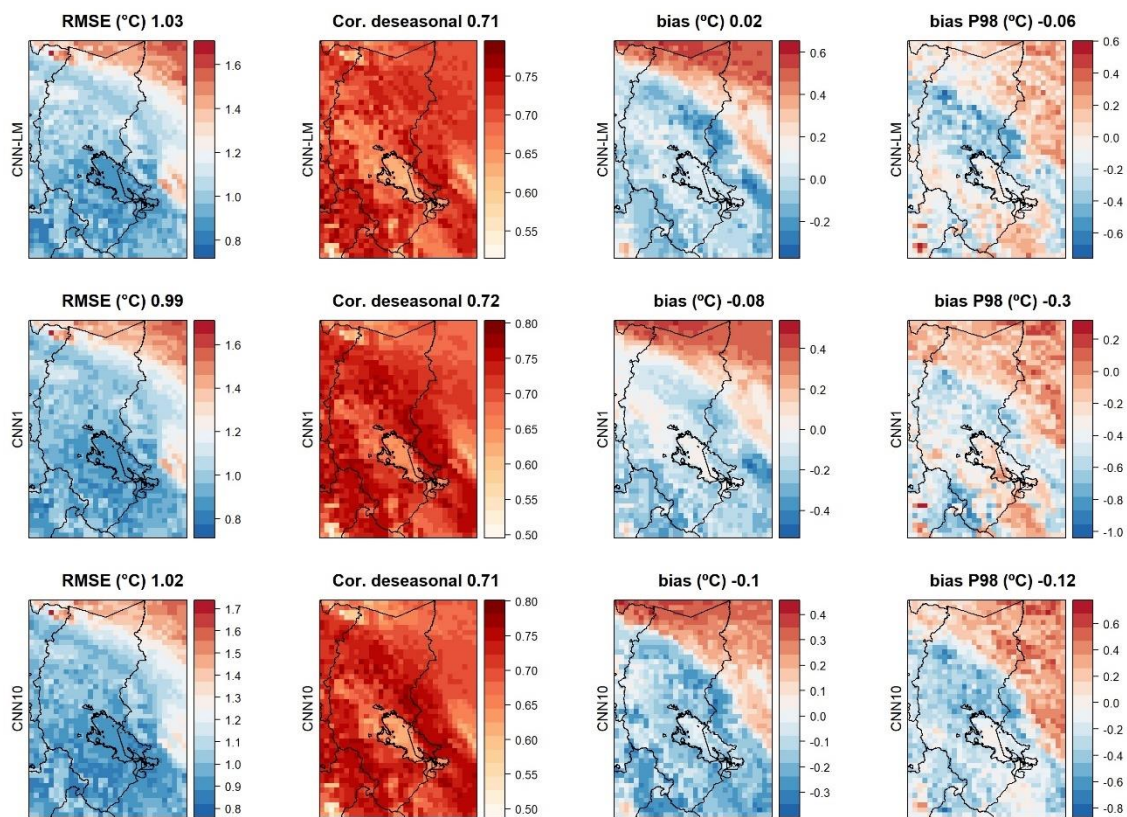


Figura 25. Comparación espacial de los métodos de regionalización estadística para la temperatura máxima
 NOTA: el número en la esquina superior derecha hace referencia a la mediana de todas las grillas del dominio.

4.2.2 Temperatura mínima

Los resultados obtenidos para la temperatura mínima se muestran como diagramas de cajas para cada método en el Figura 26. En el diagrama de cajas se evidencia que los modelos de aprendizaje profundo tienen menores RMSE y mayores correlaciones que el modelo de regresión lineal generalizada (GLM4). Sin embargo, la ratio de la desviación estándar es más alto para el GLM4 y su Bias es próximo a cero.

Para todos los modelos evaluados se tiene el Bias próximo a cero, lo cual indica un error medio bajo. La mediana del Bias en el percentil 98 es cercano a cero para los modelos GLM4, CNN1 y CNN-PR, para el CNN-LM y CNN10 predominan las sobreestimaciones; mientras que para el CNNdense predominan las subestimaciones. La mediana del Bias en el percentil 2 se encuentra por encima de 0.4°C para la mayoría de los modelos evaluados, esto indica una sobreestimación en los valores mínimos. La ratio de la desviación estándar compara la medida de dispersión de los datos del periodo de entrenamiento y de prueba; para este estadístico se observa que el modelo GLM4 tiene la mediana más alta; por tanto, es en el que más se asemeja la dispersión de los datos entre el periodo de entrenamiento y prueba; el resto de las modelos de aprendizaje profundo tienen ratios de desviación estándar superiores a 0.6.

Para determinar de manera objetiva el mejor modelo se recurrió al método de decisión multicriterio TOPSIS (Tabla 14). Del análisis TOPSIS se evidencia claramente que el modelo CNN1 es el que simula mejor los datos del periodo de prueba, ya que tiene el Bias más bajo, la correlación más alta y menor RMSE. El modelo GLM4, tiene un índice C_a de 0.91, esto indica que se trata de la segunda mejor alternativa, seguido del CNN-PR con 0.83.

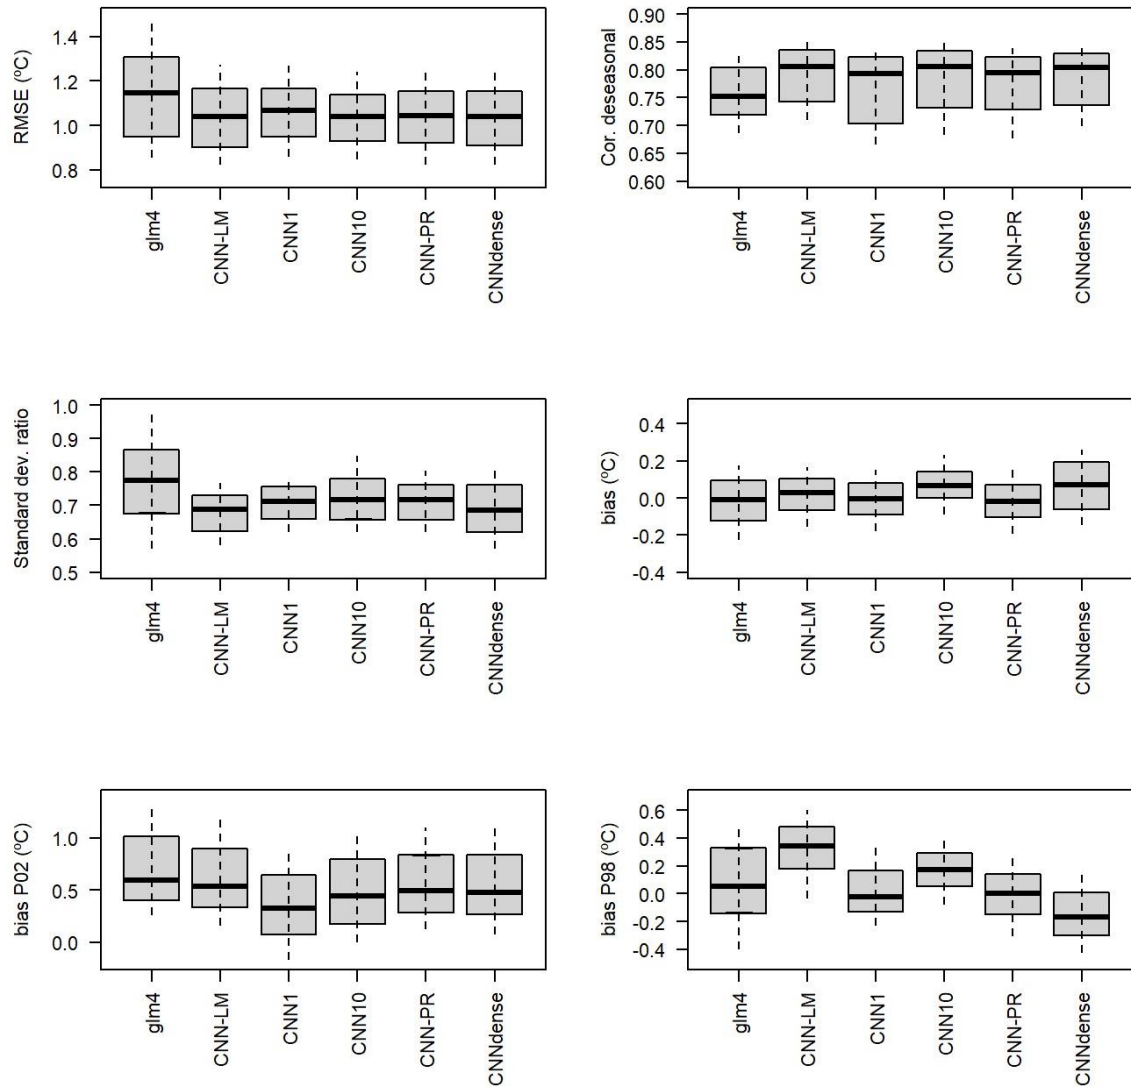


Figura 26. Comparación de los métodos de regionalización estadística para la temperatura mínima

Tabla 14: Análisis TOPSIS para temperatura mínima

Modelos	Matriz de Decisión			Modelos	Matriz de Decisión Normalizada Ponderada			Distancia a la AI (ds+)	Distancia a la AAI (ds-)	C _a
	R	BIAS	RMSE		R	BIAS	RMSE			
	max	min	min		max	min	min			
GLM4	0.75	0.01	1.15	GLM4	0.13	0.03	0.15	0.02	0.20	0.91
CNN-LM	0.81	0.03	1.04	CNN-LM	0.14	0.10	0.13	0.08	0.13	0.62
CNN1	0.79	0.01	1.07	CNN1	0.14	0.02	0.14	0.00	0.21	0.98
CNN10	0.81	0.06	1.04	CNN10	0.14	0.21	0.13	0.19	0.03	0.12
CNN-PR	0.80	0.02	1.04	CNN-PR	0.14	0.06	0.13	0.04	0.18	0.83
CNNdense	0.81	0.07	1.04	CNNdense	0.14	0.23	0.13	0.21	0.02	0.07
Peso	0.33	0.33	0.33	Alternativa Ideal (AI)	0.14	0.02	0.13	-	-	-
Norma	1.94	0.10	2.60	Alternativa Anti - Ideal (AAI)	0.13	0.23	0.15	-	-	-
NOTA:	PARA REPRESENTAR EL BIAS, RMSE Y R SE CONSIDERÓ LA MEDIANA EN VALOR ABSOLUTO.									
LEYENDA:	MEJOR MODELO DE ACUERDO CON LA METODOLOGÍA TOPSIS.									

En el Figura 27 se muestra la comparación espacial entre los métodos de regionalización estadística para la temperatura mínima, solo se realizó este análisis para los modelos con el índice Ca, del análisis TOPSIS, más alto. Para los modelos GLM4, CNN1 y CNN-PR, se evidencian mayores correlaciones para las zonas sur y central del departamento de Puno. Además, las ubicaciones próximas al Lago Titicaca tienen correlaciones bajas, sobre todo para el GLM4. En la región altiplánica central y al sur del departamento de Puno, predomina la subestimación de las predicciones para los modelos GLM4 y CNN1; al norte, en la unidad geográfica selva, predominan las sobreestimaciones. En cuanto al Bias en el percentil 2 para los modelos CNN1 y GLM4, se observa una predominancia de las sobreestimaciones a lo largo de todo el territorio del departamento de Puno; en la zona sur existen grillas con sobreestimaciones bastante altas ($> 1.5^{\circ}\text{C}$). En el lago Titicaca se observa que los valores simulados siempre sobreestiman a los datos del producto PISCO. Para el RMSE, se presentan menores valores en la zona noreste, en el resto del departamento de Puno tiene un comportamiento variable. En el Figura 27 se evidencia que se obtuvo temperatura mínima a 2 metros de la superficie con una resolución espacial de 10 km, mejorando de esta forma la resolución inicial del ERA-5 de 0.25° .

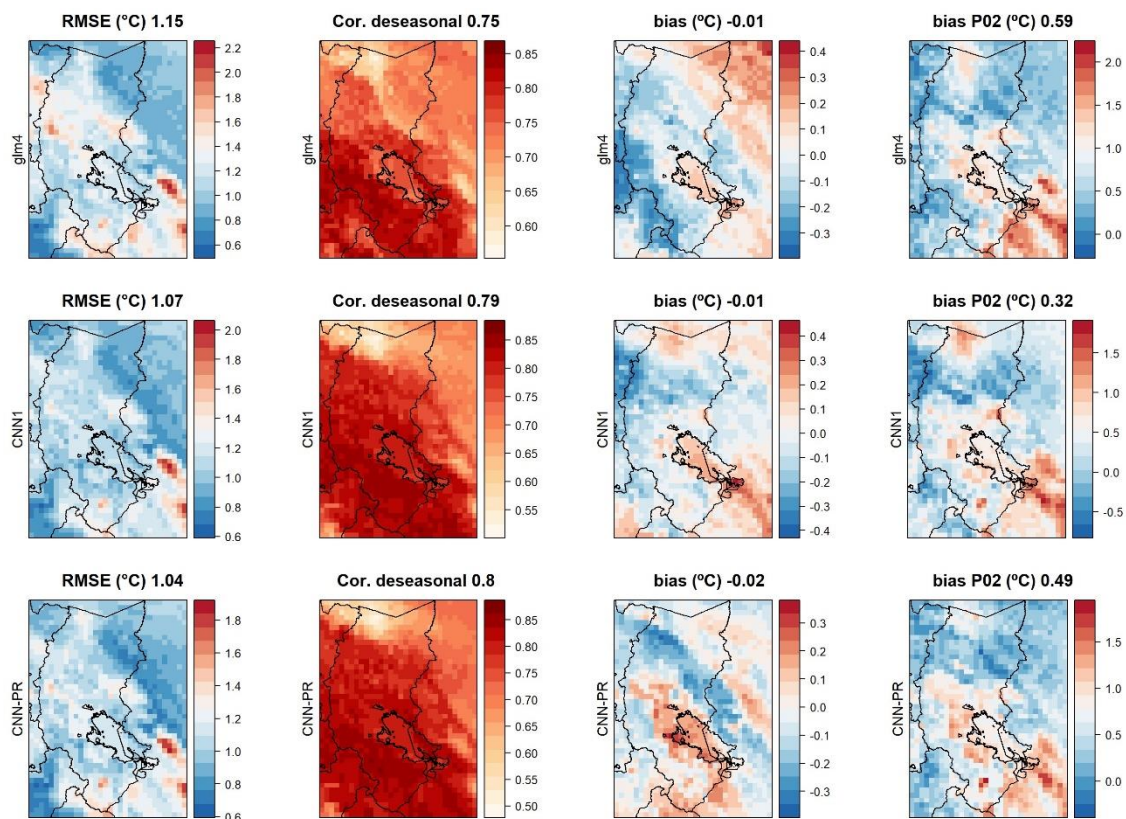


Figura 27. Comparación espacial de los métodos de regionalización estadística para la temperatura mínima
 NOTA: el número en la esquina superior derecha hace referencia a la mediana de todas las grillas del dominio.

4.3 Validación *hold out*

Los datos predichos en el periodo de prueba por los mejores modelos determinados por el método TOPSIS se compararon con los datos observados por las estaciones bajo la administración del Servicio Nacional de Meteorología e Hidrología (SENAMHI). A continuación, se muestran los resultados para la temperatura máxima y mínima.

4.3.1 Temperatura máxima

En la Tabla 15 se muestran los estadísticos de validación en el periodo de prueba del modelo CNN-LM para la temperatura máxima. Se observa que para las estaciones de Isla Suana, Lampa, Mazo Cruz y Pucara, las correlaciones son superiores a 0.7; mientras que, para las estaciones de Crucero, Huaraya Moho y Progreso las correlaciones son bajas. Para Crucero, Isla Suana y Progreso, se presentan sobreestimaciones; para Mazo cruz y Pucara subestimaciones. Las estaciones de Huaraya Moho y Lampa, tienen Bias próximos a cero. El error medio absoluto (MAE) es de aproximadamente 1 °C para todas las estaciones. Los valores de RMSE son superiores a 1 °C en todas las estaciones.

Las correlaciones varían entre valores similares a lo observado en los Gráficos espaciales de la sección 4.2.1 del presente documento; altas correlaciones al sur (estaciones Mazo Cruz e Isla Suana) y bajas en la zona central y próximas al lago Titicaca (Progreso y Huaraya Moho). En cuanto al Bias coinciden las subestimaciones de las estaciones de Huaraya Moho, Mazo Cruz y Pucara con los Gráficos espaciales de la sección 4.2, en el resto de las estaciones se observa una sobreestimación. En cuanto al RMSE el obtenido por la validación *hold out* es superior al observado con la validación VALUE en todas las estaciones.

En el Figura 28 se muestran los promedios mensuales como series de tiempo, se verifica que en las estaciones con Bias próximos a cero, los datos simulados se encuentran más próximos a los observados. Para las estaciones con Bias positivos, los simulados son superiores a los observados; para las estaciones con Bias negativos viceversa. En el Anexo B se muestran la comparación entre los datos predichos y observados a nivel diario.

Tabla 15: Estadísticos de validación por estación para la temperatura máxima

Estación	Correlación	Bias	MAE	RMSE
Crucero	0.49	0.65	1.19	1.54
Huaraya Moho	0.62	0.00	1.08	1.35
Isla Suana	0.78	0.31	0.84	1.06
Lampa	0.74	0.05	0.98	1.24
Mazo Cruz	0.72	-0.62	1.34	1.68
Progreso	0.62	0.27	1.02	1.34
Pucara	0.71	-0.12	1.00	1.26




Figura 28. Promedios mensuales para la temperatura máxima por estación

En el Figura 29 se muestra la variación mensual de la temperatura máxima por estación. Los mayores valores se observan entre octubre y diciembre; entre enero y junio la temperatura máxima oscila entre magnitudes similares. El mínimo se observa en julio para la mayoría de las estaciones; entre agosto y setiembre se observa un aumento progresivo de las temperaturas máximas.




Figura 29. Variabilidad mensual de la temperatura máxima por estación

4.3.2 Temperatura mínima

En la Tabla 16 se muestran los estadísticos de validación en el periodo de prueba del modelo CNN1 para la temperatura mínima. Se observa que para la mayoría de las estaciones las correlaciones son superiores a 0.9, solo para Isla Suana se tiene una correlación de 0.84. Para la mayoría de las estaciones se presentan sobreestimaciones, siendo Crucero y Lampa las que presentan los mayores Bias con 2.62 °C y 1.02 °C, respectivamente; para Isla Suana se observan subestimaciones. El error medio absoluto (MAE) es de aproximadamente 2 °C para todas las estaciones. Los valores de RMSE son superiores a 2 °C en la mayoría de las estaciones, pero para Huaraya Moho y Pucara se tienen valores de 1.4 °C y 1.9 °C, respectivamente. Las correlaciones son superiores a lo observado en los Gráficos espaciales de la sección 4.2.2 del presente documento para la mayoría de las estaciones, solo en Isla Suana se tienen correlaciones de similar magnitud. En cuanto al Bias coinciden las sobreestimaciones de las estaciones de Huaraya Moho, Mazo Cruz y Pucara con los Gráficos espaciales de la sección 4.2.2, el resto de las estaciones el Bias calculado por la validación *hold out* es más alto que el obtenido con la validación VALUE. En cuanto al RMSE, se tienen mayores valores a los calculados con la metodología VALUE en para la mayoría de las estaciones.

En el Figura 30 se muestran los promedios mensuales como series de tiempo, se verifica que en las estaciones con Bias más cercanos a cero, los datos simulados se encuentran más próximos a los observados. Para las estaciones con Bias positivos, los simulados son superiores a los observados; para las estaciones con Bias negativos viceversa. En el Anexo B se muestran la comparación entre los datos predichos y observados a nivel diario.

Tabla 16: Estadísticos de validación por estación para la temperatura mínima

Estación	Correlación	Bias	MAE	RMSE
Crucero	0.92	2.62	2.90	3.45
Huaraya Moho	0.91	0.37	1.08	1.40
Isla Suana	0.84	-3.44	3.46	3.80
Lampa	0.92	1.02	1.66	2.13
Mazo Cruz	0.94	0.26	2.08	2.60
Pucara	0.94	0.37	1.51	1.90




Figura 30. Promedios mensuales para la temperatura mínima por estación

En el Figura 31 se muestra la variación mensual de la temperatura mínima por estación. Se evidencia el ciclo estacional de la temperatura en todas las estaciones, con los mayores valores diciembre y febrero, luego disminuyen progresivamente entre marzo y mayo. Los mínimos se observan entre junio y agosto; entre setiembre y noviembre se observa un aumento progresivo de las temperaturas mínimas.

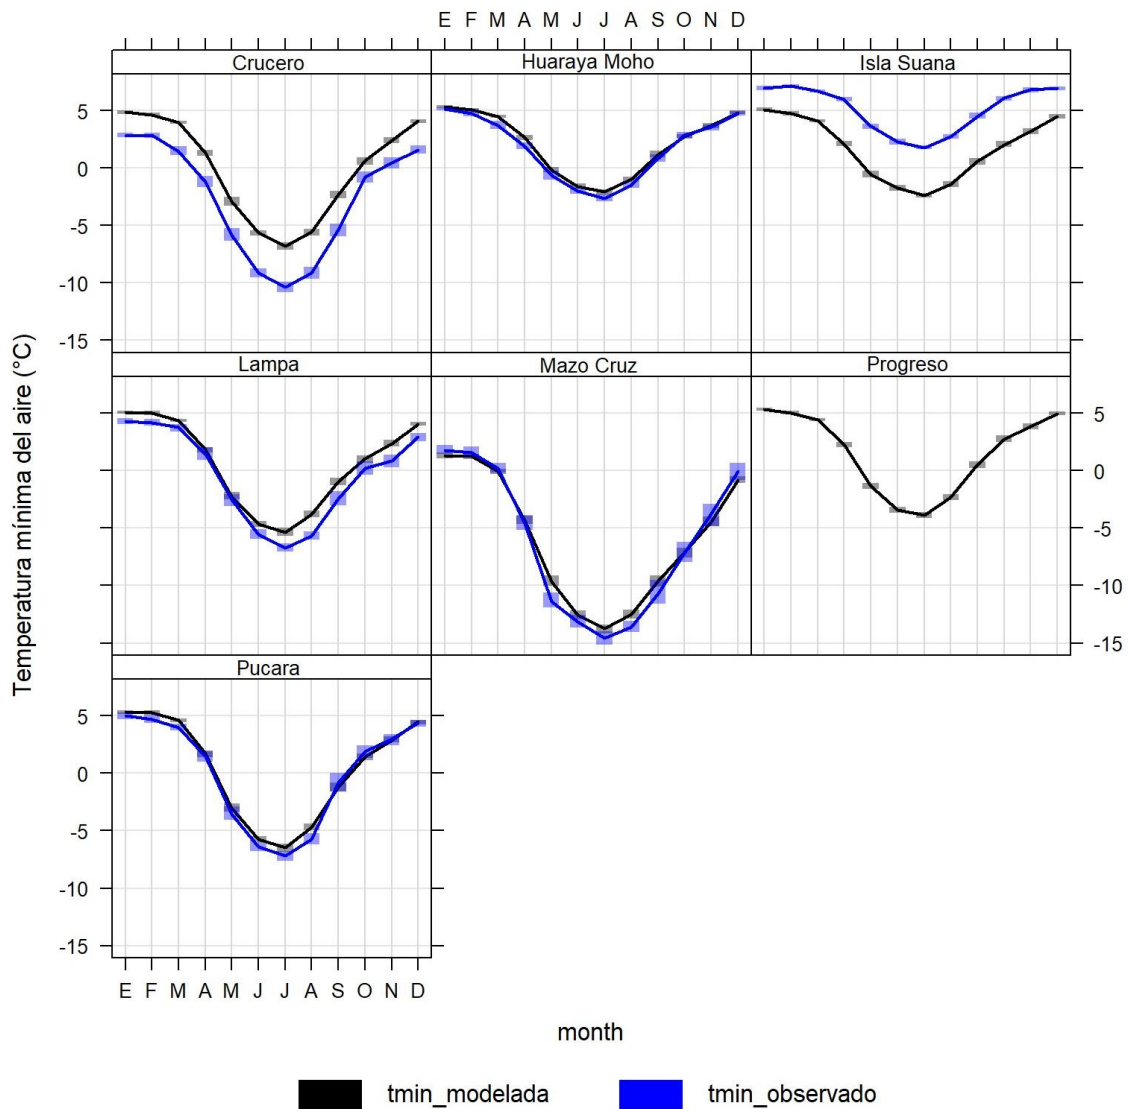


Figura 31. Promedios mensuales para la temperatura mínima por estación

4.3 Proyecciones climáticas

Las proyecciones climáticas del modelo CanESM2, experimento RCP8.5, miembro del ensamble principal (r1i1p1), se regionalizaron con los mejores modelos resultantes del método TOPSIS. Para la temperatura mínima se utilizó el modelo CNN1 y para la máxima CNN-LM.

En la Tabla 17 se observan los estadísticos de los predictandos para el periodo de histórico y la proyección. En el Figura 32 se muestra el análisis de regresión Theilsen para la temperatura máxima; en el Figura 33 se muestra lo mismo para la temperatura mínima.

Tabla 17: Estadísticos de los predictandos del dominio

Periodo	Predictando	Promedio	Mediana	Máximo	Mínimo
Histórico (1981 - 2005)	Temperatura máxima (°C)	19.54	16.99	39.93	1.10
	Temperatura mínima (°C)	4.87	2.98	26.49	-23.87
Proyección (2021 - 2040)	Temperatura máxima (°C)	20.58	17.30	38.11	7.48
	Temperatura mínima (°C)	5.69	3.12	32.07	-18.69

Al comparar los periodos históricos y de la proyección, tenemos un aumento de 1.04 °C en el promedio para la temperatura máxima y de 0.82°C para la temperatura mínima. Con lo que se conserva la tendencia inicialmente observada en los datos de PISCO, es decir que la temperatura máxima tiene una mayor tasa de calentamiento que la mínima. Además, se observa que el valor mínimo para la temperatura máxima aumentó en la proyección; sin embargo, el valor máximo disminuyó. Para la temperatura mínima se observa un aumento del valor máximo y mínimo.

Asimismo, se obtuvo temperatura máxima y mínima a 2 metros de la superficie con una resolución espacial de 10 km, mejorando de esta forma la resolución inicial del CanESM5 de 2.9°. De los análisis de regresión Theilsen para cada una de las estaciones meteorológicas empleadas en el presente estudio se desprende lo siguiente:

- Con un nivel de confianza del 99.9% existe suficiente evidencia estadística para indicar que en la estación Crucero hay una tendencia creciente para la temperatura máxima promedio mensual de 0.02 °C por año en el periodo 2021 al 2040. Es decir, se espera un aumento de 0.4 °C en 20 años.
- Con un nivel de confianza del 99% existe suficiente evidencia estadística para indicar que en las estaciones Huaraya Moho, Isla Suana, Lampa, Mazo Cruz y Progreso hay una tendencia creciente para la temperatura máxima promedio mensual de 0.02 °C por año en el periodo 2021 al 2040. Es decir, se espera un aumento de 0.4 °C en 20 años.
- Con un nivel de confianza del 99% existe suficiente evidencia estadística para indicar que en la estación Pucara hay una tendencia creciente para la temperatura máxima

promedio mensual de 0.03 °C por año en el periodo 2021 al 2040. Es decir, se espera un aumento de 0.6 °C en 20 años.

- No existe suficiente evidencia estadística para indicar que hay una tendencia significativa para la temperatura mínima en todas las estaciones evaluadas para el periodo del 2021 al 2040.




Figura 32. Análisis de regresión Theilsen para la temperatura máxima

NOTAS:

1. “***” INDICAN UN ALPHA DE 0.001, “**” INDICAN UN ALPHA DE 0.01 Y “*” INDICA UN ALFA DE 0.1.




Figura 33. Análisis de regresión Theilsen para la temperatura mínima

NOTAS:

1. “***” INDICAN UN ALPHA DE 0.001, “**” INDICAN UN ALPHA DE 0.01 Y “*” INDICA UN ALFA DE 0.1.

V. CONCLUSIONES

- El modelo de aprendizaje profundo que capta relaciones lineales entre las variables predictoras y predictandos (CNN-LM) es el que mejor simula la temperatura máxima del aire.
- El modelo de aprendizaje profundo que capta relaciones no lineales entre las variables predictoras y predictandos con un número decreciente de mapas de características (CNN1) es el que mejor simula la temperatura mínima del aire.
- Se mejoró la resolución del ERA-5 (27 km) para el periodo de prueba (2006:2010), obteniendo datos grillados cada 10 km de temperatura máxima y mínima del aire a 2 metros.
- Se mejoró la resolución del modelo CanESM5 (302 km) en el periodo del 2021 al 2040, obteniendo datos grillados cada 10 km de temperatura máxima y mínima del aire a 2 metros.
- Existe suficiente evidencia estadística para concluir con un 99.9% de confianza que hay una tendencia creciente de 0.4°C para la estación Crucero en el periodo 2021 al 2040. Asimismo, con un 99% se concluye que hay una tendencia creciente de 0.4°C en las estaciones de Huaraya Moho, Isla Suana, Lampa, Mazo Cruz y Progreso. Finalmente, con un 99% de confianza existe suficiente evidencia estadística para concluir que hay una tendencia creciente de 0.6°C en la estación Pucará para el mismo periodo de 20 años.
- No existe suficiente evidencia estadística para terminar una tendencia significativa para la temperatura mínima en las estaciones evaluadas en el departamento de Puno en el periodo 2021 al 2040.
- Es posible aplicar la técnica de CNN para la regionalización estadística de temperatura máxima y mínima en el departamento de Puno, en específico para la zona del altiplano, que abarca la ladera oriental, la cordillera oriental y occidental; tanto para nivel climatológico como para las proyecciones futuras.

VI. RECOMENDACIONES

- Se recomienda seguir investigando con más variables predictoras y otros modelos y configuración de la arquitectura de los modelos de CNN, para determinar la influencia de ello en la regionalización de escenarios futuros.
- Aplicar el procedimiento planteado en el presente estudio a otros departamentos del Perú para ver la capacidad de extrapolación de la técnica de aprendizaje profundo.
- Regionalizar modelos del CMIP6 y CMIP5 con distintos miembros del ensamble, para evaluar a influencia de la variación de las condiciones iniciales. Asimismo, se recomienda incluir los modelos contemplen años bisiestos para que tengan consistencia temporal con los datos de PISCO y ERA-5.
- Comparar los resultados de la regionalización estadística con métodos de aprendizaje profundo con un modelo de regionalización dinámica.

VII. BIBLIOGRAFÍA

- Ahmed, K. F., Wang, G., Silander, J., Wilson, A. M., Allen, J. M., Horton, R., & Anyah, R. (2013). Statistical downscaling and bias correction of climate model outputs for climate change impact assessment in the U.S. northeast. *Global and Planetary Change*, 100, 320–332. <https://doi.org/10.1016/j.gloplacha.2012.11.003>
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4(none). <https://doi.org/10.3978/j.issn.2072-1439.2014.09.09>
- Avalos Roldán, G., & Quispe Gutiérrez, N. (2000). Condiciones Sinópticas de la Incursión de una Masa de Aire Frío en Sudamérica: caso julio 2000 y su impacto en la Selva Peruana. *Servicio Nacional de Meteorología e Hidrología*, 1–9.
- Bagnato, J. (2020). *Aprende Machine Learning en Español Teoría + Práctica Python*. LeanPub, 176.
- Baño-Medina, J., Manzanas, R., & Gutiérrez, J. M. (2019). Configuration and intercomparison of deep learning neural models for statistical downscaling. *Geoscientific Model Development*, 13(4), 2109–2124. <https://doi.org/10.5194/gmd-13-2109-2020>
- Barreto Schuler, C. W. (2016). *COMPORTAMIENTO DE LA ALTA DE BOLIVIA HACIA FINALES DEL SIGLO XXI BAJO EL ESCENARIO DE EMISIÓN RCP8.5*. Universidad Nacional Agraria La Molina, 105.
- BCRP. (2023). Caracterización del Departamento de Puno. In *Análisis Económico Regional* (Vol. 2). Recuperado de: <https://www.google.com/maps/place/Puno/@-15.0833935,-70.421316,7.75z/data=!4m5!3m4!1s0x915cc50c7ad1a787:0x772bc030ccdd9916!8m2!3d-15.234875!4d-70.050314>

- Bedia, J., Baño-Medina, J., Legasa, M. N., Iturbide, M., Manzanas, R., Herrera, S., Casanueva, A., San-Martín, D., Cofiño, A. S., & Gutiérrez, J. M. (2019). Statistical downscaling with the downscaleR package (v3.1.0): Contribution to the VALUE intercomparison experiment. *Geoscientific Model Development*, *13*(3), 1711–1735. <https://doi.org/10.5194/gmd-13-1711-2020>
- Benestad, R. E., Chen, D., & Hanssen-Bauer, I. (2007). *Empirical-Statistical Downscaling*. Earth Sciences Centre, Gothenburg University.
- Bhoumik, D. (2018). *Deep Learning: Techniques and Applications Seminar Paper Contents*.
- Boé, J., Terray, L., Habets, F., & Martin, E. (2006). A simple statistical-dynamical downscaling scheme based on weather types and conditional resampling. *Journal of Geophysical Research: Atmospheres*, *111*(D23). <https://doi.org/10.1029/2005JD006889>
- Brooks, N., & Adger, N. (2003). *Country level risk measures of climate-related natural disasters and implications for adaptation to climate change*.
- Brunelli, A. (2014). A synopsis of resampling techniques. *Journal of Thoracic Disease*, *Vol 6*(No 12). <https://doi.org/10.3978/j.issn.2072-1439.2014.09.09>
- Brunke, M. A. (2011). *The Components of a Climate Model*. Recuperado de: <https://www.u.arizona.edu/~brunke/modeling/model-components.html>
- Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P. W., Trisos, C., Romero, J., Aldunce, P., Barrett, K., Blanco, G., Cheung, W. W. L., Connors, S., Denton, F., Diongue-Niang, A., Dodman, D., Garschagen, M., Geden, O., Hayward, B., Jones, C., ... & Ha, M. (2023). SYNTHESIS REPORT OF THE IPCC SIXTH ASSESSMENT REPORT (AR6). In *IPCC*.
- Carslaw, D. (2019). *The openair manual: open-source tools for analysing air pollution data* (Issue November). Recuperado de: <https://davidcarslaw.com/files/openairmanual.pdf>
- Castro, A., Davila, C., Laura, W., Cubas, F., Avalos, G., López Ocaña, C., Villena, D., Valdez, M., Urbiola, J., Trebejo, I., Menis, L., & Marín, D. (2021). Climas del Perú Mapa de Clasificación Climática Nacional. In *Ministerio del Ambiente*. SENAMHI.
- Chapman, W. E., Subramanian, A. C., Delle Monache, L., Xie, S. P., & Ralph, F. M. (2019).

- Improving Atmospheric River Forecasts With Machine Learning. *Geophysical Research Letters*, 46(17–18), 10627–10635. <https://doi.org/10.1029/2019GL083662>
- Chen, S.-C., Roads, J. O., Juang, H.-M. H., & Kanamitsu, M. (1999). Global to regional simulations of California wintertime precipitation. *Journal of Geophysical Research: Atmospheres*, 104(D24), 31517–31532. <https://doi.org/10.1029/1998JD200043>
- CMIP. (2023). *CMIP Data Access*. <https://wcrp-cmip.org/cmip-data-access/#:~:text=A list of all experiments,contributed by a single model>.
- CSIRO. (2020). *CLIMATE MODELS*. Commonwealth Science Industrial Research Organisation. Recuperado de: <https://www.climatechangeinaustralia.gov.au/en/learning-support/climate-models/>
- Cubasch, U., Meehl, G. A., Boer, G. J., Stouffer, R. J., Dix, M., Noda, A., Senior, C. A., Raper, S., Yap, K. S., Abe-Ouchi, Brinkop, S., Claussen, M., Collins, M., Evans, J., Flato, G., Fyfe, J. C., Ganopolski, A., Gregory, J. M., Hu, Z., ... & Zwiers, F. (2001). Projections of Future Climate Change. In J.-W. Kim & J. Stone (Eds.), *Climate Change 2001* (pp. 525–582). IPCC.
- Cubasch, U., Wuebbles, D., Chen, D., Facchin, M. C., Frame, D., Mahowald, N., & Winther, J.-G. (2013). Introduction, Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. In T. F. Stocker, D. Qin, G.-K. Plattner, M. Tignor, S. K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, & M. Midgley (Eds.), *Climate Change 2013: The Physical Science Basis*. (Cambridge, pp. 119–158). IPCC.
- De la Cruz, G., & Acuña, D. (2019). *Statistical downscaling of climate scenarios in Peruvian Central Andes*. Recuperado de: <https://app.ingemmet.gob.pe/biblioteca/pdf/TGS-21.pdf>
- Déqué, M., Rowell, D. P., Lüthi, D., Giorgi, F., Christensen, J. H., Rockel, B., Jacob, D., Kjellström, E., de Castro, M., & van den Hurk, B. (2007). An intercomparison of regional climate simulations for Europe: assessing uncertainties in model projections. *Climatic Change*, 81(S1), 53–70. <https://doi.org/10.1007/s10584-006->

- ECMRWF. (2022). *ERA5*. Recuperado de:
<https://confluence.ecmwf.int/display/CKB/ERA5%3A+data+documentation#ERA5:datadocumentation-Introduction>
- ECMWF. (2018). *ERA5 hourly data on single levels from 1940 to present*. Recuperado de:
<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=overview>
- Efron, B., & Gong, G. (1983). A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation. *The American Statistician*, 37(1), 36. <https://doi.org/10.2307/2685844>
- Eltahir, E., & Krol, A. (2021). *Climate Models*. Massachusetts Institute of Technology (MIT). Recuperado de: <https://climate.mit.edu/explainers/climate-models>
- Fedderson, H., & Andersen, U. (2005). A method for statistical downscaling of seasonal ensemble predictions. *Tellus A: Dynamic Meteorology and Oceanography*, 57(3), 398. <https://doi.org/10.3402/tellusa.v57i3.14656>
- Gerard, L. (2007). An integrated package for subgrid convection, clouds and precipitation compatible with meso-gamma scales. *Quarterly Journal of the Royal Meteorological Society*, 133(624), 711–730. <https://doi.org/10.1002/qj.58>
- Gestión. (2023). *Lago Titicaca reporta disminución de 0.74 metros en nivel del agua*. Diario Gestión. En los últimos años, nuestra manera de desplazarnos ha cambiado debido a la aparición de las plataformas de intermediación de movilidad que ofrecen experiencias de transporte más confiables y eficientes. La explosión de estos nuevos métodos de transporte
- Gómez-Navarro, J. J., Montávez, J. P., Jerez, S., Jiménez-Guerrero, P., Lorente-Plazas, R., González-Rouco, J. F., & Zorita, E. (2011). A regional climate simulation over the Iberian Peninsula for the last millennium. *Climate of the Past*, 7(2), 451–472. <https://doi.org/10.5194/cp-7-451-2011>
- Gong, G. (1986). Cross-Validation, the Jackknife, and the Bootstrap: Excess Error Estimation in Forward Logistic Regression. *Journal of the American Statistical Association*, 81(393), 108. <https://doi.org/10.2307/2287975>
- Gonzales, D. (2021). *Por qué las noches se están calentando más rápido que los días (y cómo eso puede ayudar a la ciencia a entender el cambio climático)*. BBC NEWS

- MUNDO. Recuperado de: <https://www.bbc.com/mundo/noticias-57927923>
- GRP. (2013). Plan de Desarrollo Regional Concertado Puno al 2021. In *Gobierno Regional de Puno (GRP)*. regionpuno.gob.pe/descargas/planes/actualizacion-pdrc-2021/PARTE-I-puno-28-2014-pdrc-al-2021.pdf
- Guy, J., & Rebaza, C. (2023). *El lago Titicaca, el cuerpo de agua navegable más alto del mundo, se está secando*. Cable News Network (CNN). Recuperado de: <https://cnnespanol.cnn.com/2023/09/03/lago-titicaca-bolivia-peru-niveles-de-agua-sequia-trax/>
- Han, J. M., Ang, Y. Q., Malkawi, A., & Samuelson, H. W. (2021). Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements. *Building and Environment*, *192*, 107601. <https://doi.org/10.1016/j.buildenv.2021.107601>
- Hawkins, D. M., Basak, S. C., & Mills, D. (2003). Assessing Model Fit by Cross-Validation. *Journal of Chemical Information and Computer Sciences*, *43*(2), 579–586. <https://doi.org/10.1021/ci025626i>
- Hernández, C. (2019). *Deep Learning*. <https://blogs.sas.com/content/sasla/2019/09/30/porque-es-importante-el-deep-learning/>
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., ... & Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, *146*(730), 1999–2049. <https://doi.org/10.1002/qj.3803>
- Hofer, M., Marzeion, B., & Mölg, T. (2015). A statistical downscaling method for daily air temperature in data-sparse, glaciated mountain environments. *Geoscientific Model Development*, *8*(3), 579–593. <https://doi.org/10.5194/gmd-8-579-2015>
- Houghton, J., Izrael, Y. A., & Reinstein, R. A. (1992). *Cambio Climático: La evaluación del IPCC de 1990 y 1992*. http://ipcc.ch/ipccreports/1992_IPCC_Supplement/IPCC_1990_and_1992_Assessments/Spanish/ipcc_90_92_assessments_far_full_report_sp.pdf
- Huerta, A., Aybar, C., & Lavado-Casimiro, W. (2018). SENAMHI - PISCO temperatura v. 1.1. SENAMHI. *Senamhi - Dhi-2018, 1.1, 1–15*.

http://iridl.ldeo.columbia.edu/documentation/.pisco/.PISCOt_report.pdf

Hurtado, C. (2007). *Evaluación de modelos de clasificación*.

INDECI. (2021). *Compendio Estadístico*.

INEI. (2014). *Perú: Principales Indicadores Departamentales 2008-2014*. Recuperado de: https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1205/mapas/mapa23.pdf

IPCC. (2001). *Climate Change: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change*. In *Cambridge University Press*.

IPCC. (2014). Informe Del Grupo Intergubernamental De Expertos Sobre El Cambio Climático. In *Contribución de los Grupos de trabajo I,II y III al Quinto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático*. https://www.ipcc.ch/site/assets/uploads/2018/02/SYR_AR5_FINAL_full_es.pdf

IPCC. (2022). *IPCC Sixth Assessment Report Impacts, Adaptation and Vulnerability*. Recuperado de: <https://www.ipcc.ch/report/ar6/wg2/>

IPCC. (2023). *History of the IPCC*. Recuperado de: <https://www.ipcc.ch/about/history/>

Iturbide, M., Bedia, J., Herrera, S., Baño-Medina, J., Fernández, J., Frías, M. D., Manzanas, R., San-Martín, D., Cimadevilla, E., Cofiño, A. S., & Gutiérrez, J. M. (2019). The R-based climate4R open framework for reproducible climate data access and post-processing. *Environmental Modelling & Software*, *111*, 42–54. <https://doi.org/10.1016/j.envsoft.2018.09.009>

Jolliffe, I. T., & Stephenson, D. B. (2011). Chapter 1: Introduction. In I. T. Jolliffe & D. B. Stephenson (Eds.), *Forecast Verification* (pp. 1–9). Wiley. <https://doi.org/10.1002/9781119960003>

Karna, N., Chandra Roy, P., & Shakya, S. (2021). *Temperature Prediction using Regression Model*. 4(2). Recuperado de: <https://www.researchgate.net/publication/353164124>

Kennedy, C., & Lindsey, R. (2018). *¿Cuál es la diferencia entre el calentamiento global y el cambio climático?* NOAA. Recuperado de: <https://www.climate.gov/news-features/climate-qa/¿cuál-es-la-diferencia-entre-el-calentamiento-global-y-el-cambio-climático#:~:text=El calentamiento global se refiere,o las sequías más>

frecuentes.

- Laing, A., & Evans, J.-L. (2016). Introducción a la meteorología tropical. In *COMET Program* (2nd ed.). COMET Program. Recuperado de: https://www.meted.ucar.edu/sign_in.php?go_back_to=/tropical/textbook_2nd_edition_es/print_1.htm
- Llamocca Huamani, J. (2022). Regionalización Estadística de Escenarios Climáticos con CMIP5 para el Perú. *Revista Geográfica*, 164, 99–111. <https://doi.org/10.35424/regeo.164.2022.1085>
- Maldonado Calani, J. M. (2020). *Resumen Sinóptico “Enero 2020.”*
- Maraun, D., Wetterhall, F., Ireson, A. M., Chandler, R. E., Kendon, E. J., Widmann, M., Brienen, S., Rust, H. W., Sauter, T., Themeßl, M., Venema, V. K. C., Chun, K. P., Goodess, C. M., Jones, R. G., Onof, C., Vrac, M., & Thiele-Eich, I. (2010). Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, 48(3), RG3003. <https://doi.org/10.1029/2009RG000314>
- Maraun, D., & Widmann, M. (2018). Cross-validation of bias-corrected climate simulations is misleading. *Hydrology and Earth System Sciences*, 22(9), 4867–4873. <https://doi.org/10.5194/hess-22-4867-2018>
- Maraun, D., Widmann, M., Gutiérrez, J. M., Kotlarski, S., Chandler, R. E., Hertig, E., Wibig, J., Huth, R., & Wilcke, R. A. I. (2015a). VALUE: A framework to validate downscaling approaches for climate change studies. *Earth’s Future*, 3(1), 1–14. <https://doi.org/10.1002/2014EF000259>
- Maraun, D., Widmann, M., Gutiérrez, J. M., Kotlarski, S., Chandler, R. E., Hertig, E., Wibig, J., Huth, R., & Wilcke, R. A. I. (2015b). VALUE: A framework to validate downscaling approaches for climate change studies. *Earth’s Future*, 3(1), 1–14. <https://doi.org/10.1002/2014EF000259>
- Marinucci, M. R., & Giorgi, F. (1992). A 2XCO₂ climate change scenario over Europe generated using a limited area model nested in a general circulation model: 1. Present-day seasonal climate simulation. *Journal of Geophysical Research: Atmospheres*, 97(D9), 9989–10009. <https://doi.org/10.1029/92JD00615>
- Mason, S. J. (2008). Understanding forecast verification statistics. *Meteorological*

Applications, 15(1), 31–40. <https://doi.org/10.1002/met.51>

- Mercado, F. R., García Fernández, W., & Acebey, J. A. H. (2016). Sistema de inteligencia artificial para la predicción temprana de heladas meteorológicas Artificial intelligence system for early prediction of weather frost. *Acta Nova*, 7, 1683–0768.
- Meteoblue. (2018). *Verification report for forecast and historical weather data Air temperature*. 1–11.
- Michaelson, J. (1987). Cross-Validation in Statistical Climate Forecast Models. *Journal of Climate and Applied Meteorology*, 26(11), 1589–1600. [https://doi.org/10.1175/1520-0450\(1987\)026<1589:CVISCF>2.0.CO;2](https://doi.org/10.1175/1520-0450(1987)026<1589:CVISCF>2.0.CO;2)
- MINAM. (2009). Cambio climático y Desarrollo Sostenible en el Perú. In *Global Environment Facility*. Recuperado de: <https://www.gob.pe/institucion/minam/informes-publicaciones/306347-cambio-climatico-y-desarrollo-sostenible-en-el-peru>
- Moons, K. G. M., Altman, D. G., Reitsma, J. B., Ioannidis, J. P. A., Macaskill, P., Steyerberg, E. W., Vickers, A. J., Ransohoff, D. F., & Collins, G. S. (2015). Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): Explanation and Elaboration. *Annals of Internal Medicine*, 162(1), W1–W73. <https://doi.org/10.7326/M14-0698>
- Morata-Gasca, A. (2014). *Guía de escenarios regionalizados de cambio climático sobre España a partir de los resultados del IPCC-AR4*. Recuperado de: http://www.aemet.es/documentos/es/conocermas/publicaciones/Guia_IPCC/Guia_IPC_C.pdf
- NASA. (2023). *What is climate change?* <https://climate.nasa.gov/what-is-climate-change/>
- NOAA. (2023). *Climate Models*. National Ocean and Atmospheric Administration. Recuperado de: <https://www.climate.gov/maps-data/climate-data-primer/predicting-climate/climate-models>
- Nourani, V., Uzelaltinbulat, S., Sadikoglu, F., & Behfar, N. (2019). Artificial intelligence based ensemble modeling for multi-station prediction of precipitation. *Atmosphere*, 10(2). <https://doi.org/10.3390/atmos10020080>
- O’Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*. December. Recuperado de: <http://arxiv.org/abs/1511.08458>

- Pradhan, R., Aygun, R. S., Maskey, M., Ramachandran, R., & Cecil, D. J. (2018). Tropical Cyclone Intensity Estimation Using a Deep Convolutional Neural Network. *IEEE Transactions on Image Processing*, 27(2), 692–702. <https://doi.org/10.1109/TIP.2017.2766358>
- Quintero Plaza, D. (2022). MACHINE LEARNING Y METEOROLOGÍA: UN ENCAJE PERFECTO. *Aemetblog*. Recuperado de: https://aemetblog.es/2022/08/07/machine-learning-y-meteorologia-un-encaje-perfecto/?fbclid=IwAR2t_OC3gl0xnPfm_RZfuu_jjGPzMzaygdIt4ICQVmCI3p2r49QGGvqWF8g
- R Core Team. (2022). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. Recuperado de: <https://www.r-project.org/>
- Ramon, J., Lledó, L., Bretonnière, P.-A., Samsó, M., & Doblas-Reyes, F. J. (2021). A perfect prognosis downscaling methodology for seasonal prediction of local-scale wind speeds. *Environmental Research Letters*, 16(5), 054010. <https://doi.org/10.1088/1748-9326/abe491>
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195–204. <https://doi.org/10.1038/s41586-019-0912-1>
- Rodríguez, M. (2019). *Análisis de validación cruzada bajo diferentes condiciones de ruido*.
- Rouhiainen, L. (2008). Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro. In *Alienta editorial*. Recuperado de: https://planetadelibrosar0.cdnstatics.com/libros_contenido_extra/40/39307_Inteligencia_artificial.pdf
- RStudio Team. (2020). *RStudio: Integrated Development for R*. PBC, Boston, MA.
- Sanabria, J., Marengo, J., & Valverde, M. (2009). *Escenarios de Cambio Climático con modelos regionales sobre el Altiplano Peruano (Departamento de Puno)*.
- SENAMHI. (2013). Evaluación de los modelos CMIP5 del IPCC en el Perú : proyecciones al año 2030 en la región Puno. *Repositorio Institucional - SENAMHI*, 1–31. <http://repositorio.senamhi.gob.pe/handle/20.500.12542/221#.XuusqN7L42g.mend>

eley

- SENAMHI. (2014). *Regionalización Estadística de Escenarios Climáticos en Perú* (1st ed.).
- Song, Y. H., Shahid, S., & Chung, E. S. (2021). Differences in multi-model ensembles of CMIP5 and CMIP6 projections for future droughts in South Korea. *International Journal of Climatology*, 1–46. <https://doi.org/10.1002/joc.7386>
- Stainforth, D. ., Allen, M. ., Tredger, E. ., & Smith, L. . (2007). Confidence, uncertainty and decision-support relevance in climate predictions. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1857), 2145–2161. <https://doi.org/10.1098/rsta.2007.2074>
- Stone, M. (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2), 111–133. <https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>
- Sulca, J., Vuille, M., Timm, O. E., Dong, B., & Zubieta, R. (2021). Empirical–Statistical Downscaling of Austral Summer Precipitation over South America, with a Focus on the Central Peruvian Andes and the Equatorial Amazon Basin. *Journal of Applied Meteorology and Climatology*, 60(1), 65–85. <https://doi.org/10.1175/JAMC-D-20-0066.1>
- Taylor, K. E., Durack, P. J., Elkington, M., Guilyardi, E., Hassell, D., Lautenschlager, M., & Stockhause, M. (2022). *CMIP6 Participation Guidance for Modelers*. Recuperado de: <https://pcmdi.llnl.gov/CMIP6/Guide/modelers.html>
- UCAR. (2017). Análisis de superficie. In *Elementos de cartografía meteorológica*. University Corporation of Atmospheric Research. Recuperado de: https://www.meted.ucar.edu/intromet/charting_es/navmenu.php?tab=1&page=2-3-0&type=flash
- UCAR. (2021). Sistemas de vientos. In *Curso intermedio S-290 sobre el comportamiento de los incendios forestales*. University Corporation of Atmospheric Research. Recuperado de: https://www.meted.ucar.edu/intromet/charting_es/navmenu.php
- Vandal, T., Kodra, E., & Ganguly, A. R. (2017). Intercomparison of Machine Learning Methods for Statistical Downscaling: The Case of Daily and Extreme Precipitation. *Theoretical and Applied Climatology*, 137(1–2), 557–570. <https://doi.org/10.1007/s00704-018-2613-3>

- Viñas, J. M. (2019). *Conocer la meteorología*. Alianza Editorial S.A.
- Wang, J., Balaprakash, P., & Kotamarthi, R. (2019). Fast domain-aware neural network emulation of a planetary boundary layer parameterization in a numerical weather forecast model. *Geoscientific Model Development*, *12*(10), 4261–4274. <https://doi.org/10.5194/gmd-12-4261-2019>
- Wilby, R. L., & Wigley, T. M. L. (2000). Precipitation predictors for downscaling: observed and general circulation model relationships. *International Journal of Climatology*, *20*, 641–661.
- Wilby, R. L., Wigley, T. M. L., Conway, D., Jones, P. D., Hewitson, B. C., Main, J., & Wilks, D. S. (1998). Statistical downscaling of general circulation model output: A comparison of methods. *Water Resources Research*, *34*(11), 2995–3008. <https://doi.org/10.1029/98WR02577>
- Wilks, D. S. (2007). *Statistical methods in the atmospheric sciences*, second edition. In *Meteorological Applications* (Vol. 14, Issue 2).
- WMO. (2022). *Estado del Sistema Mundial de Observación del Clima*. Organización Meteorológica Mundial. Recuperado de: <https://public.wmo.int/es/resources/bulletin/estado-del-sistema-mundial-de-observación-del-clima>
- WMO. (2023). *State of the Climate in Latin America and the Caribbean 2022* (Issue 1295). World Meteorological Organization (WMO). Recuperado de: <https://library.wmo.int/records/item/66252-state-of-the-climate-in-latin-america-and-the-caribbean-2022>
- Wolfensberger, D., Gabella, M., Boscacci, M., Germann, U., & Berne, A. (2021). RainForest: a random forest algorithm for quantitative precipitation estimation over Switzerland. *Atmospheric Measurement Techniques*, *14*(4), 3169–3193. <https://doi.org/10.5194/amt-14-3169-2021>
- Zorita, E., & von Storch, H. (1999). The Analog Method as a Simple Statistical Downscaling Technique: Comparison with More Complicated Methods. *Journal of Climate*, *12*(8), 2474–2489. [https://doi.org/10.1175/1520-0442\(1999\)012<2474:TAMAAS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012<2474:TAMAAS>2.0.CO;2)

VIII. ANEXOS

Anexo 1: Validación de estaciones meteorológicas bajo administración del SENAMHI en el departamento de Puno.

Procedimiento de validación

La validación de las estaciones meteorológicas del SENAMHI (SENAMHI, 2021) abarca los siguientes pasos:

1. Verificación de valores nulos.
2. Validación de rango nacional.
3. Validación de rango blando.
4. Validación de consistencia interna.
5. Tratamiento de registros duplicados.
6. Rellenado de días incompletos.
7. Validación de consistencia temporal: i) prueba de paso y ii) prueba de persistencia.

Verificación de valores nulos

Implica la transformación de los valores -99.9 o “S/D” como “NA”. Asimismo, todos los datos con simbología “NaN”, se transformaron a “NA”. Todos los datos transformados se codificaron como “2.3”.

Validación de rango nacional.

En estas pruebas, los datos que cumplan los límites son marcados como válidos y los que no cumplan son marcados como inválidos. Los límites nacionales para Perú se muestran en la Tabla 1. Los datos que pasaban esta prueba se categorizaban como datos válidos (“0”), sino se codificaban como “1.1”.

Tabla 1. Rangos para límites nacionales

Parámetro	Rango		Fuente
	Mínimo	Máximo	
Temperatura	-32 °C	45 °C	SENAMHI, 2021

Validación de rango blando

Para la validación de rango blando se compararon los registros con la climatología de la estación. Asimismo, para determinar los rangos de variación se utilizó el Z-score. Es preciso indicar que en caso de que un dato no cumpla con este criterio, no se invalida directamente, sino que se marca como sospechoso y se le codifica como “1.2”. Solo se invalidará un dato sospechoso si no cumple con alguno de los criterios posteriores.

Validación de consistencia interna

Se toma en cuenta las relaciones meteorológicas que existen entre las observaciones efectuadas en la misma estación. Valores medidos al mismo tiempo y en el mismo lugar no pueden ser inconsistentes entre ellos. (AENOR, 2004). Si los registros no cumplían con la consistencia interna se le codificó como “2”. Esta prueba abarca los siguientes criterios:

1. La temperatura máxima no puede ser menor que la temperatura mínima.
2. La temperatura mínima no puede ser mayor que la temperatura máxima.

Tratamiento de registros duplicados

En caso de registros duplicados se verifica la desviación estándar de los valores, en caso de que la desviación estándar sea mayor a 0.1 para el caso de la temperatura mínima y máxima se le considerará como duplicado. Los registros duplicados no serán considerados como válidos y se codificarán como “2.2”.

Rellenado de días incompletos

El relleno de días incompletos se refiere a completar con “NA” los días que no salen en los registros de las estaciones del SENAMHI. Los registros completados se codificarán con “2.3”.

Validación de la Consistencia Temporal

Se compara el cambio entre observaciones consecutivas. Si la diferencia excede un valor permitido, distinto para cada parámetro, el dato será etiquetado como “sospechoso”. Si alguno de los dos datos usados en la comparación no existe, en este paso no se etiquetará el dato, a no ser que no se vaya a aplicar ninguna otra validación, entonces se etiquetará como “sospechoso” (AENOR, 2004).

1.1.1 Prueba de paso

La diferencia entre dos datos próximos de temperatura del aire horaria no debe exceder de un límite preestablecido (SENAMHI, 2021). Si los registros no cumplen con la prueba de paso se le codificará con “3.1”, en caso de que el dato ya esté clasificado como sospechoso por alguna otra prueba, se procederá a invalidar. En la Tabla 2 se muestran los criterios para la prueba de paso, es preciso indicar que, aunque la prueba de paso se aplica en la referencia para datos horarios, para nivel diario se verificó que cumpliera con los 5 criterios en simultáneo para ser invalidado.

Tabla 2. Pruebas de paso

Parámetro	Paso	Condición
Temperatura	1 día	$ T_d - T_{d-1} \leq 4^\circ C$
	2 días	$ T_d - T_{d-2} \leq 7^\circ C$
	3 días	$ T_d - T_{d-3} \leq 9^\circ C$
	6 días	$ T_d - T_{d-6} \leq 15^\circ C$
	12 días	$ T_d - T_{d-12} \leq 25^\circ C$

1.1.2 Prueba de persistencia

Para temperatura máxima y mínima del aire se considera si el dato diario tiene el mismo valor que los datos registrados en los tres días anteriores consecutivos, se marcarán todos los valores en la secuencia como dudoso (Adaptado de Meek & Hatfield, 1994). Si los registros no cumplen con la prueba de persistencia se le codificará con “3.2”, en caso de que el dato ya esté clasificado como sospechoso por alguna otra prueba, se procederá a invalidar.

Resultados de la validación

Variables	Estaciones	Validación	Porcentaje (%)	Total de datos analizados
Temperatura máxima diaria	Crucero	0	36	11317
		1.2	0	11317
		2.3	63	11317
		3.1	1	11317
	Huaraya Moho	0	94	11317
		2.3	4	11317
		3.1	2	11317
	Isla Suana	0	98	7487
		2.3	1	7487
		3.1	1	7487
	Lampa	0	94	11317
		1.2	0	11317
		2.3	4	11317
		3.1	2	11317
	Mazo Cruz	0	90	11317
		2.3	6	11317
		3.1	3	11317
	Progreso	0	88	11317
		1.2	0	11317
		2.3	9	11317
		3.1	3	11317
	Pucara	0	48	11317
		1.2	0	11317
		2.3	50	11317
3.1		1	11317	
Temperatura mínima diaria	Crucero	0	32	11317
		2.3	63	11317
		3.1	5	11317
	Huaraya Moho	0	94	11317
		2.3	4	11317
		3.1	2	11317
	Isla Suana	0	98	7487
		2.3	1	7487
		3.1	0	7487
	Lampa	0	86	11317
		2.3	4	11317
		3.1	10	11317
	Mazo Cruz	0	71	11317
		2.3	6	11317
		3.1	23	11317
	Progreso	2.3	100	11317
	Pucara	0	43	11317
		2.3	50	11317
		3.1	7	11317

NOTAS:

LOS NÚMEROS DE LA VALIDACIÓN SIGNIFICAN LO SIGUIENTE:

0: DATOS VÁLIDOS.

1.1: DATOS INVALIDADOS POR EXCEDER EL RANGO NACIONAL.

1.2: DATOS INVALIDADOS POR EXCEDER EL RANGO BLANDO.

2: DATOS INVALIDADOS POR NO CUMPLIR CON LA PRUEBA DE CONSISTENCIA INTERNA.

2.2: DATOS DUPLICADOS.

2.3: DÍAS INCMPLETOS COMPLETADOS POR "NA".

3.1: DATOS INVALIDADOS POR LA PRUEBA DE PASO.

3.2: DATOS INVALIDADOS POR LA PRUEBA DE PERSISTENCIA.

Referencias

AENOR. (2004). *Redes de estaciones meteorológicas automáticas: Directrices para la validación de registros meteorológicos procedentes de redes de estaciones automáticas*. Asociación Española de Normalización y Certificación.

Meek, D. W., Hatfield, J.L., 1994: *Data quality checking for single station meteorological databases*. Agric. For. Meteor., 69, 85-109

SENAMHI. (2021). Control de calidad de datos de estaciones meteorológicas e hidrológicas automáticas en el centro de procesamiento de datos del SENAMHI. In *Subdirecció de gestió de datos*.

Anexo 2: Comparación entre valores simulados y observados para la temperatura promedio diaria.

Gráfico B.1. Temperatura mínima del aire observada y modelada





Gráfico B.2. Temperatura máxima del aire observada y modelada



Anexo 3: Proyecciones climáticas del CMIP a nivel mensual

Tabla C.1. Proyecciones mensuales para la temperatura mínima

Estación	Año	Temperatura mínima (°C)											
		Enero	Fe- brero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Setiembre	Octu- bre	Noviem- bre	Diciem- bre
Crucero	2021	4.62	5.18	4.51	1.79	-1.27	-5.04	-6.31	-4.49	-1.40	0.80	2.38	3.90
	2022	4.68	5.44	4.26	1.67	-1.54	-4.41	-6.11	-5.19	-2.08	0.23	2.19	3.41
	2023	4.88	5.02	4.24	0.87	-1.78	-5.80	-5.93	-4.36	-1.70	0.64	2.43	4.36
	2024	5.01	5.32	4.01	2.35	-1.42	-4.08	-5.72	-4.59	-1.86	0.82	2.21	3.71
	2025	5.19	4.74	4.08	2.43	-1.53	-4.92	-6.21	-5.02	-2.49	0.03	1.95	3.73
	2026	5.12	5.33	4.59	2.51	-1.24	-4.74	-5.26	-4.20	-1.64	0.79	2.62	4.12
	2027	5.34	5.28	4.25	2.51	-0.39	-3.28	-4.96	-4.24	-1.85	0.55	2.75	4.44
	2028	5.10	5.24	4.48	2.27	-1.36	-4.56	-5.36	-4.38	-1.70	0.51	2.31	3.92
	2029	5.39	4.73	4.11	2.30	-2.11	-4.89	-6.31	-4.78	-1.14	0.66	2.27	3.87
	2030	4.33	4.61	4.53	1.95	-0.51	-3.52	-4.84	-4.10	-1.36	0.86	2.80	4.39
	2031	5.57	5.41	3.97	1.99	-0.75	-4.08	-5.72	-4.56	-1.40	1.17	3.05	4.50
	2032	5.07	4.94	4.66	2.64	-0.09	-2.73	-4.29	-3.43	-1.27	0.43	2.68	4.68
	2033	5.48	5.43	4.59	2.72	-0.88	-4.34	-4.86	-4.56	-1.91	1.10	2.33	3.77
	2034	5.34	5.25	3.77	2.22	-1.44	-4.47	-5.31	-4.10	-1.69	0.63	2.44	4.44
	2035	4.83	5.36	4.39	2.67	-1.03	-3.86	-5.14	-4.37	-1.27	0.88	2.85	4.78
	2036	5.44	5.75	5.27	2.70	-1.36	-3.52	-5.39	-4.88	-1.14	0.98	3.13	3.93
	2037	5.02	5.31	4.58	2.91	-0.35	-4.67	-4.71	-3.90	-0.75	1.47	2.83	4.45
	2038	5.23	5.14	4.42	1.84	-1.17	-4.25	-5.45	-3.63	-0.88	1.38	2.97	4.76
	2039	5.36	5.08	4.35	2.62	-0.72	-3.29	-4.62	-3.75	-1.10	0.88	2.18	4.73
	2040	5.38	5.43	4.32	2.38	-0.51	-3.56	-5.27	-4.38	-0.59	1.94	2.63	4.76

Continuación ...

	2021	4.92	5.29	4.70	2.74	0.74	-1.54	-2.06	-0.61	1.34	2.74	3.59	4.42
	2022	5.02	5.28	4.52	2.83	0.69	-1.24	-1.98	-1.11	1.02	2.30	3.50	4.14
	2023	5.10	5.17	4.51	2.26	0.32	-1.89	-1.63	-0.55	1.34	2.74	3.76	4.71
	2024	5.14	5.26	4.41	3.10	0.70	-1.04	-1.63	-0.76	1.16	2.96	3.45	4.31
	2025	5.25	4.96	4.49	3.46	0.65	-1.54	-1.72	-0.97	0.63	2.25	3.29	4.25
	2026	5.15	5.42	4.91	3.40	0.62	-1.50	-1.24	-0.41	1.47	2.91	3.64	4.48
	2027	5.43	5.15	4.57	3.37	1.34	-0.53	-1.43	-0.62	0.90	2.54	3.89	4.92
	2028	5.15	5.25	4.72	3.18	0.46	-1.46	-1.44	-0.66	1.10	2.65	3.59	4.56
	2029	5.44	5.15	4.44	3.21	0.21	-1.42	-1.98	-0.63	1.80	2.85	3.73	4.32
Huaraya Moho	2030	4.67	4.90	4.80	3.04	1.31	-0.71	-1.00	-0.52	1.53	2.99	3.86	4.72
	2031	5.48	5.35	4.49	2.91	1.17	-0.92	-1.48	-0.55	1.64	3.22	3.89	4.88
	2032	5.17	5.18	4.86	3.41	1.54	0.13	-0.74	0.01	1.52	2.53	3.85	4.98
	2033	5.44	5.43	4.76	3.40	0.91	-1.28	-1.33	-0.91	1.00	2.94	3.59	4.46
	2034	5.36	5.40	4.24	3.20	0.60	-1.33	-1.46	-0.41	1.28	2.64	3.65	4.77
	2035	5.01	5.43	4.61	3.37	0.80	-0.95	-1.38	-0.63	1.49	2.80	3.78	5.00
	2036	5.39	5.55	5.28	3.39	0.61	-0.66	-1.20	-0.78	1.66	2.87	4.05	4.35
	2037	5.22	5.42	4.78	3.51	1.30	-1.39	-1.05	-0.23	1.93	3.27	3.74	4.82
	2038	5.33	5.20	4.83	2.88	0.81	-1.04	-1.47	0.01	1.86	3.27	3.95	4.96
	2039	5.44	5.19	4.86	3.35	1.00	-0.42	-0.97	-0.25	1.53	2.91	3.49	4.91
	2040	5.41	5.41	4.80	3.16	1.16	-0.58	-1.30	-0.52	1.96	3.46	3.71	4.87
	2021	4.54	5.01	4.41	2.29	0.26	-1.60	-2.29	-1.16	0.74	2.14	3.15	4.08
	2022	4.74	5.00	4.09	2.19	0.14	-1.54	-2.31	-1.50	0.42	1.84	3.08	3.77
	2023	4.82	4.87	4.17	1.77	0.09	-2.16	-1.95	-1.01	0.66	2.11	3.35	4.36
Isla Suana	2024	4.85	4.85	3.88	2.59	0.24	-1.47	-1.92	-1.21	0.49	2.25	3.00	3.93
	2025	4.95	4.56	3.96	2.73	0.18	-1.72	-2.08	-1.38	0.13	1.77	2.83	3.95
	2026	4.84	5.12	4.44	2.74	0.26	-1.66	-1.67	-0.96	0.75	2.15	3.19	4.08
	2027	4.91	4.63	4.00	2.64	0.71	-0.98	-1.85	-1.24	0.26	1.91	3.41	4.52

Continuación ...

2028	4.84	4.92	4.42	2.53	0.11	-1.69	-1.70	-1.21	0.47	1.91	3.15	4.40
2029	5.30	4.77	4.05	2.63	-0.12	-1.70	-2.13	-1.08	1.07	2.16	3.16	4.05
2030	4.41	4.52	4.20	2.38	0.70	-1.20	-1.52	-1.07	0.76	2.19	3.37	4.40
2031	5.13	5.08	4.04	2.16	0.58	-1.48	-1.77	-1.21	0.81	2.37	3.38	4.46
2032	4.71	4.45	4.14	2.69	0.82	-0.51	-1.39	-0.83	0.67	1.78	3.27	4.58
2033	4.98	5.06	4.12	2.80	0.33	-1.51	-1.60	-1.33	0.38	2.39	3.07	4.20
2034	5.24	5.16	3.82	2.60	0.25	-1.56	-1.90	-1.02	0.57	2.06	3.13	4.38
2035	4.78	5.02	4.13	2.75	0.23	-1.29	-1.71	-1.27	0.73	2.19	3.36	4.63
2036	5.16	5.33	4.84	2.88	0.21	-1.05	-1.73	-1.19	0.97	2.27	3.50	3.99
2037	4.83	4.94	4.07	2.83	0.67	-1.60	-1.53	-0.77	1.09	2.61	3.25	4.47
2038	4.97	4.70	4.28	2.31	0.22	-1.52	-1.92	-0.79	1.10	2.54	3.46	4.52
2039	5.09	4.73	4.24	2.79	0.38	-0.99	-1.60	-0.85	0.80	2.19	2.91	4.60
2040	5.03	5.12	4.22	2.66	0.69	-1.29	-1.74	-1.11	1.16	2.77	3.21	4.42
2021	4.79	5.43	4.70	1.98	-1.17	-4.19	-5.23	-3.18	-0.45	1.38	2.46	3.90
2022	4.95	5.26	4.36	1.71	-1.23	-3.98	-5.22	-3.60	-0.85	0.93	2.37	3.37
2023	4.83	5.13	4.39	1.09	-1.60	-5.11	-4.71	-3.10	-0.72	1.42	2.54	4.25
2024	5.14	5.31	4.06	2.24	-1.47	-3.70	-4.53	-3.26	-0.96	1.44	2.33	3.65
2025	5.15	4.90	4.24	2.66	-1.24	-4.62	-4.73	-3.58	-1.44	0.89	2.07	3.53
2026	5.27	5.61	4.86	2.71	-1.26	-4.20	-3.98	-2.91	-0.42	1.58	2.61	3.78
2027	5.17	4.83	4.14	2.32	-0.70	-3.10	-4.42	-3.22	-0.96	1.10	2.84	4.09
2028	5.16	5.45	4.73	2.27	-1.46	-4.14	-4.18	-3.29	-0.61	1.36	2.56	3.90
2029	5.65	5.22	4.37	2.46	-1.76	-4.39	-4.93	-3.25	-0.20	1.44	2.47	3.74
2030	4.52	4.84	4.43	1.88	-0.44	-3.45	-3.83	-3.12	-0.28	1.54	2.90	4.15
2031	5.58	5.48	4.35	1.85	-0.81	-3.87	-4.39	-3.30	-0.51	1.39	2.70	4.17
2032	4.38	4.48	4.07	2.05	-0.72	-2.56	-3.70	-2.70	-0.58	0.75	2.75	4.35
2033	5.33	5.44	4.65	2.59	-1.17	-3.94	-4.22	-3.41	-0.94	1.63	2.44	3.80
2034	5.81	5.51	4.05	2.41	-1.53	-3.99	-4.31	-2.89	-0.80	1.23	2.47	4.41

Lampa

Continuación ...

	2035	4.89	5.26	4.70	2.53	-1.18	-3.65	-4.08	-3.19	-0.44	1.36	2.87	4.72
	2036	5.44	5.66	5.24	2.56	-1.19	-3.27	-3.96	-3.50	-0.34	1.45	2.90	3.54
	2037	4.91	5.24	4.42	2.60	-0.48	-4.24	-3.95	-2.69	-0.10	1.96	2.66	4.30
	2038	5.48	5.09	4.54	1.85	-1.09	-3.88	-4.31	-2.58	0.02	1.83	2.91	4.32
	2039	5.19	5.13	4.52	2.23	-1.07	-2.98	-3.81	-2.71	-0.31	1.46	2.35	4.34
	2040	5.17	5.30	4.62	2.43	-0.49	-3.11	-4.01	-3.21	0.15	2.23	2.43	4.11
	2021	0.72	1.83	0.15	-4.54	-8.72	-12.22	-13.46	-11.53	-8.83	-6.57	-3.54	-1.04
	2022	1.32	0.81	-0.64	-5.07	-8.93	-11.86	-13.51	-11.84	-9.31	-6.95	-4.56	-1.73
	2023	0.73	1.13	0.02	-5.61	-8.92	-13.23	-12.93	-11.22	-8.91	-6.72	-4.20	-0.33
	2024	0.91	1.31	-1.03	-4.12	-9.23	-11.73	-12.48	-11.64	-9.71	-6.71	-4.48	-1.26
	2025	1.32	0.32	-1.02	-3.69	-8.72	-12.77	-13.10	-11.84	-10.09	-7.11	-4.77	-1.74
	2026	1.17	1.86	-0.07	-3.33	-8.53	-11.94	-12.24	-11.42	-8.96	-7.02	-4.00	-1.52
	2027	0.39	-0.12	-1.60	-4.60	-8.51	-11.16	-12.30	-12.29	-9.59	-7.17	-3.85	-0.61
	2028	0.84	1.26	0.15	-3.85	-8.82	-12.34	-12.54	-11.76	-9.05	-7.23	-4.52	-0.72
	2029	2.15	1.54	-0.51	-3.82	-9.38	-12.43	-13.08	-11.81	-8.90	-6.82	-4.54	-1.71
Mazo Cruz	2030	-0.08	-0.30	-1.16	-5.19	-8.29	-11.45	-12.48	-11.55	-9.22	-7.24	-4.45	-0.74
	2031	1.67	1.14	-1.23	-5.22	-8.54	-12.63	-13.00	-12.55	-9.50	-6.64	-4.42	-1.63
	2032	-1.87	-2.46	-2.80	-5.74	-9.51	-11.53	-12.65	-12.20	-9.71	-7.93	-4.35	-0.72
	2033	0.69	0.99	-0.96	-3.99	-8.84	-12.04	-12.19	-12.20	-9.36	-6.24	-4.41	-1.01
	2034	1.92	1.93	-0.50	-3.24	-8.73	-11.86	-12.88	-11.60	-9.24	-7.03	-4.23	-0.34
	2035	0.55	1.42	-0.55	-3.38	-9.02	-11.91	-12.58	-11.94	-9.30	-7.10	-3.69	-0.21
	2036	1.60	1.78	0.55	-3.66	-8.60	-11.55	-12.38	-12.12	-8.64	-6.67	-3.44	-1.87
	2037	-0.01	0.32	-1.50	-4.46	-8.51	-12.40	-12.78	-11.37	-8.89	-6.46	-3.99	-1.14
	2038	0.81	0.46	-0.53	-4.56	-8.77	-12.24	-12.73	-11.85	-8.99	-6.55	-3.94	-0.98
	2039	0.43	0.22	-0.93	-4.46	-8.82	-11.07	-12.40	-11.41	-9.12	-6.89	-4.67	-0.58
	2040	1.35	0.96	-0.48	-4.38	-8.36	-11.82	-12.50	-11.97	-8.83	-5.59	-4.60	-1.17
Progreso	2021	5.21	5.50	4.91	2.61	-0.22	-3.14	-3.80	-1.59	1.18	2.87	3.82	4.70

Continuación ...

2022	5.24	5.60	4.68	2.62	-0.10	-2.76	-3.73	-2.38	0.59	2.40	3.80	4.43
2023	5.37	5.43	4.64	1.98	-0.70	-3.69	-3.14	-1.55	0.88	2.95	3.96	5.02
2024	5.57	5.51	4.40	2.91	-0.20	-2.28	-3.11	-1.83	0.82	3.15	3.59	4.54
2025	5.53	5.23	4.63	3.26	-0.33	-3.23	-3.15	-2.31	0.13	2.28	3.49	4.57
2026	5.52	5.64	5.09	3.09	-0.25	-2.90	-2.71	-1.36	1.09	3.05	3.91	4.84
2027	5.75	5.45	4.71	3.30	0.53	-1.80	-3.00	-1.56	0.66	2.68	4.16	5.19
2028	5.58	5.55	4.96	2.91	-0.56	-2.99	-2.84	-1.70	0.94	2.95	3.86	4.78
2029	5.76	5.21	4.43	2.97	-0.89	-2.96	-3.54	-1.65	1.45	3.03	3.85	4.64
2030	5.00	5.15	5.04	3.07	0.73	-2.14	-2.20	-1.50	1.34	3.31	4.42	5.00
2031	5.78	5.74	4.67	2.64	0.35	-2.29	-2.82	-1.50	1.39	3.28	4.19	5.24
2032	5.49	5.46	5.12	3.27	0.84	-1.02	-2.04	-0.67	1.23	2.54	4.24	5.39
2033	5.72	5.77	4.90	3.23	0.01	-2.68	-2.96	-1.87	0.53	3.15	3.88	4.83
2034	5.80	5.58	4.15	2.88	-0.49	-2.74	-2.74	-1.33	0.85	2.87	3.97	5.28
2035	5.27	5.69	4.97	3.11	-0.15	-2.34	-2.63	-1.61	1.29	3.10	4.18	5.48
2036	5.69	5.89	5.62	3.20	-0.27	-1.92	-2.53	-1.98	1.22	3.12	4.20	4.59
2037	5.52	5.75	4.95	3.44	0.57	-2.88	-2.45	-1.01	1.70	3.61	4.10	5.30
2038	5.68	5.33	4.79	2.61	0.00	-2.36	-2.83	-0.71	1.63	3.50	4.37	5.34
2039	5.70	5.49	4.95	3.14	0.16	-1.59	-2.33	-1.19	1.43	3.02	3.72	5.33
2040	5.75	5.70	5.05	2.99	0.49	-1.78	-2.60	-1.49	1.87	3.78	4.12	5.26
2021	5.11	5.71	5.10	1.85	-1.96	-5.48	-6.49	-3.90	-0.39	1.69	2.95	4.31
2022	5.19	5.69	4.62	1.57	-1.90	-5.14	-6.41	-4.65	-0.98	1.15	2.83	3.77
2023	5.29	5.65	4.66	0.99	-2.41	-6.39	-5.81	-3.87	-0.56	1.78	3.09	4.70
2024	5.39	5.65	4.30	2.24	-2.16	-4.75	-5.73	-4.15	-0.82	1.99	2.90	4.03
2025	5.47	5.22	4.42	2.59	-1.98	-5.82	-5.89	-4.46	-1.64	1.05	2.44	3.91
2026	5.59	5.97	5.17	2.59	-1.91	-5.44	-5.14	-3.60	-0.41	1.93	2.95	4.27
2027	5.51	5.13	4.35	2.28	-1.19	-4.10	-5.69	-3.99	-1.14	1.42	3.24	4.82
2028	5.52	5.89	4.98	2.34	-2.16	-5.37	-5.34	-4.02	-0.75	1.59	2.94	4.39

Pucara

Continuación ...

2029	6.14	5.51	4.62	2.46	-2.59	-5.46	-6.11	-3.88	0.04	1.94	2.97	4.17
2030	4.83	5.00	4.74	1.92	-1.13	-4.55	-4.84	-3.69	-0.39	2.02	3.41	4.66
2031	5.70	5.79	4.41	1.63	-1.43	-5.03	-5.65	-4.09	-0.45	1.86	2.99	4.54
2032	4.78	4.98	4.22	1.96	-1.38	-3.49	-4.75	-3.25	-0.43	1.07	3.11	4.74
2033	5.61	5.73	4.78	2.45	-1.82	-5.20	-5.41	-4.38	-1.12	1.87	2.81	4.27
2034	6.07	5.94	4.27	2.28	-2.11	-5.12	-5.58	-3.59	-0.76	1.62	3.02	4.87
2035	5.22	5.64	5.06	2.42	-2.01	-4.74	-5.23	-4.06	-0.33	1.81	3.31	5.06
2036	5.66	6.07	5.90	2.74	-2.02	-4.37	-5.14	-4.34	-0.27	1.88	3.36	3.94
2037	5.23	5.61	4.68	2.54	-1.24	-5.47	-5.03	-3.15	0.10	2.47	3.14	4.71
2038	5.67	5.52	4.91	1.74	-1.70	-4.95	-5.50	-3.05	0.23	2.38	3.41	4.90
2039	5.57	5.37	4.95	2.30	-1.76	-3.89	-4.94	-3.39	-0.30	1.67	2.61	4.85
2040	5.73	5.84	4.98	2.33	-1.10	-4.19	-5.24	-3.93	0.35	2.75	2.99	4.68

Tabla C.1. Proyecciones mensuales para la temperatura máxima

Estación	Año	Temperatura máxima (°C)											
		Enero	Fe- brero	Marzo	Abril	Mayo	Ju- nio	Julio	Agosto	Setiem- bre	Octu- bre	Noviem- bre	Diciem- bre
Crucero	2021	14.79	14.79	15.03	15.37	15.24	14.70	14.56	15.32	16.07	16.14	15.96	15.53
	2022	14.81	15.11	15.28	15.67	15.62	14.91	14.86	15.10	15.95	16.19	16.09	15.52
	2023	14.96	14.77	15.18	15.39	15.23	14.81	14.74	15.53	15.67	16.18	16.07	15.35
	2024	15.03	15.00	15.24	15.56	15.50	15.17	14.78	15.33	16.30	16.61	16.12	15.58
	2025	15.02	15.13	15.42	15.80	15.35	14.72	15.14	15.41	15.69	16.14	16.17	15.62
	2026	15.01	14.94	15.36	15.37	15.31	14.90	15.22	15.67	15.79	16.69	16.06	15.94
	2027	15.14	15.50	15.61	15.92	15.50	15.58	15.08	15.75	16.37	16.47	16.28	15.51
	2028	15.04	15.13	15.30	15.37	15.00	14.93	14.73	15.33	16.25	16.52	16.04	15.50
	2029	14.77	14.72	15.22	15.30	15.01	14.63	14.60	15.39	15.90	16.24	16.15	15.60
	2030	15.19	15.21	15.58	15.89	15.89	15.50	15.52	15.58	16.27	16.57	16.45	15.54
	2031	14.92	15.02	15.39	15.72	15.48	15.29	15.05	15.68	16.38	16.58	16.46	15.97
	2032	16.26	16.34	15.92	15.94	15.97	15.83	15.61	16.33	16.71	16.88	16.51	15.79
	2033	15.34	15.14	15.68	15.61	15.42	14.88	14.91	15.53	16.23	16.53	16.37	15.67
	2034	14.92	14.84	15.21	15.45	15.16	14.91	15.10	15.57	16.19	16.69	16.16	15.53
	2035	14.91	15.22	15.37	15.38	15.24	15.10	15.19	15.69	16.53	16.74	16.29	15.71
	2036	15.33	15.25	15.22	15.65	15.05	15.29	15.19	15.44	15.94	16.22	16.17	15.63
	2037	15.04	15.02	15.50	15.89	15.64	15.23	15.27	15.85	16.44	16.86	16.46	15.83
	2038	15.24	15.38	15.48	15.75	15.67	15.48	15.60	16.06	16.22	16.61	16.59	15.75
	2039	15.24	15.09	15.49	15.89	15.63	15.72	15.40	15.92	16.54	16.88	16.47	15.67
	2040	15.40	15.34	15.41	15.53	15.62	15.42	15.33	15.82	16.62	16.35	16.32	16.00
2021	15.38	15.36	15.40	15.31	14.70	13.97	13.93	14.73	15.72	16.02	16.11	15.78	

Continuación ...

	2022	15.18	15.54	15.59	15.57	15.05	14.18	14.30	14.58	15.46	15.94	16.16	15.94
	2023	15.42	15.25	15.45	15.16	14.66	14.26	14.11	14.93	15.31	16.03	16.32	15.83
	2024	15.34	15.43	15.42	15.51	15.04	14.57	14.08	14.75	15.80	16.38	16.16	15.79
	2025	15.47	15.60	15.71	15.68	14.90	14.08	14.24	14.50	15.27	16.03	16.26	15.88
	2026	15.37	15.37	15.74	15.30	14.91	14.27	14.58	14.88	15.42	16.40	16.15	16.11
	2027	15.71	15.66	15.75	15.70	15.12	14.79	14.42	14.76	15.84	16.33	16.51	16.04
	2028	15.60	15.54	15.65	15.41	14.67	14.31	14.11	14.82	15.72	16.49	16.28	15.96
	2029	15.32	15.35	15.47	15.24	14.62	14.12	13.84	14.71	15.63	15.92	16.15	15.82
	2030	15.58	15.65	15.65	15.69	15.25	14.65	14.70	14.89	15.96	16.36	16.55	15.93
Huaraya Moho	2031	15.55	15.53	15.69	15.50	15.01	14.58	14.21	14.94	15.84	16.54	16.54	16.16
	2032	16.58	16.60	16.00	15.73	15.48	15.10	14.63	15.67	16.24	16.48	16.69	16.17
	2033	15.91	15.64	15.97	15.64	14.97	14.22	14.34	14.85	15.73	16.35	16.60	16.12
	2034	15.55	15.39	15.40	15.48	14.87	14.22	14.34	15.01	15.63	16.38	16.33	15.92
	2035	15.63	15.75	15.65	15.46	14.80	14.51	14.49	15.02	16.22	16.48	16.36	16.07
	2036	15.79	15.68	15.63	15.61	14.73	14.56	14.44	14.68	15.55	16.18	16.41	15.95
	2037	15.73	15.61	15.52	15.69	15.21	14.48	14.60	15.30	16.23	16.57	16.61	16.13
	2038	15.77	15.80	15.90	15.61	15.11	14.73	14.74	15.39	15.72	16.50	16.68	16.28
	2039	15.82	15.62	15.75	15.59	15.14	15.08	14.71	15.38	15.96	16.63	16.62	16.27
	2040	15.77	15.89	15.76	15.51	15.12	14.74	14.55	15.08	16.25	16.31	16.42	16.28
	2021	15.72	15.64	15.87	15.75	15.23	14.32	14.24	14.93	15.98	16.38	16.57	16.12
	2022	15.62	15.91	16.13	16.15	15.50	14.50	14.51	14.65	15.88	16.30	16.70	16.28
	2023	15.83	15.62	15.92	15.72	15.07	14.35	14.41	15.15	15.66	16.37	16.80	16.07
	2024	15.86	15.69	15.92	15.86	15.36	14.71	14.23	14.86	16.20	16.76	16.74	16.37
Isla Suana	2025	15.81	16.07	16.21	16.17	15.30	14.24	14.56	14.81	15.51	16.52	16.68	16.26
	2026	15.84	15.79	16.29	15.77	15.35	14.45	14.68	15.17	15.69	16.88	16.66	16.45
	2027	16.05	16.12	16.36	16.20	15.49	15.14	14.66	14.93	16.13	16.66	16.96	16.51
	2028	16.02	15.94	16.05	15.92	15.05	14.60	14.34	15.00	16.12	16.94	16.83	16.35

Continuación ...

	2029	15.82	15.60	16.09	15.90	15.09	14.32	14.06	14.97	15.90	16.24	16.57	16.33
	2030	16.07	16.05	16.04	16.25	15.75	14.97	14.96	15.16	16.14	16.78	16.91	16.28
	2031	15.63	15.87	15.97	15.96	15.43	14.93	14.34	15.15	16.08	16.77	16.89	16.46
	2032	17.01	17.08	16.56	16.23	15.85	15.52	14.99	15.93	16.55	16.83	17.22	16.50
	2033	16.16	15.93	16.28	16.21	15.42	14.40	14.52	14.94	15.97	16.76	17.04	16.45
	2034	15.88	15.87	15.91	15.92	15.15	14.51	14.46	15.21	15.89	16.83	16.80	16.24
	2035	16.07	15.93	16.21	15.88	15.07	14.74	14.71	15.15	16.47	16.87	16.94	16.50
	2036	16.03	16.05	16.04	16.03	15.04	14.89	14.62	14.98	15.90	16.51	16.69	16.22
	2037	15.89	15.80	16.08	16.15	15.53	14.83	14.83	15.42	16.34	16.96	17.08	16.49
	2038	16.16	16.20	16.35	16.15	15.57	14.93	15.04	15.61	16.03	16.80	17.03	16.61
	2039	16.27	15.92	16.24	16.05	15.38	15.17	14.86	15.41	16.29	17.08	17.00	16.50
	2040	16.14	16.26	16.10	15.91	15.58	15.08	14.66	15.25	16.53	16.65	16.79	16.57
	2021	16.79	16.63	16.76	16.94	16.62	16.01	15.94	16.69	17.81	17.96	17.93	17.31
	2022	16.69	16.94	17.04	17.33	17.07	16.35	16.32	16.47	17.52	17.89	17.99	17.60
	2023	16.88	16.58	16.92	16.97	16.58	16.19	16.10	16.99	17.24	17.78	18.00	17.29
	2024	16.87	16.74	17.03	17.07	16.94	16.56	16.10	16.68	17.97	18.32	18.05	17.46
	2025	16.86	16.95	17.18	17.38	16.78	16.02	16.43	16.69	17.32	17.99	18.06	17.54
	2026	16.90	16.69	17.18	16.99	16.82	16.25	16.53	17.04	17.39	18.35	17.92	17.73
	2027	17.14	17.27	17.42	17.41	16.94	16.94	16.44	16.98	18.01	18.20	18.30	17.67
Lampa	2028	16.94	16.81	16.95	17.00	16.52	16.26	16.16	16.91	17.84	18.54	18.20	17.50
	2029	16.71	16.64	17.00	17.02	16.51	16.03	15.86	16.82	17.47	17.87	17.92	17.52
	2030	17.07	17.10	17.04	17.42	17.25	16.80	16.84	17.14	17.78	18.34	18.34	17.39
	2031	16.83	16.88	17.11	17.24	16.99	16.65	16.20	17.04	17.86	18.38	18.35	17.80
	2032	18.13	18.17	17.57	17.39	17.38	17.10	16.89	17.95	18.30	18.56	18.52	17.72
	2033	17.16	16.90	17.36	17.33	16.89	16.21	16.21	16.94	17.76	18.33	18.51	17.68
	2034	16.91	16.79	16.88	17.09	16.58	16.27	16.34	17.09	17.58	18.35	18.18	17.47
	2035	17.02	16.99	17.10	16.99	16.69	16.60	16.53	17.14	18.13	18.38	18.20	17.59

Continuación ...

	2036	17.08	16.98	17.02	17.15	16.55	16.62	16.45	16.69	17.48	17.99	18.14	17.58
	2037	17.04	16.90	17.10	17.29	17.07	16.58	16.62	17.29	18.01	18.49	18.40	17.62
	2038	17.21	17.29	17.32	17.29	17.04	16.80	16.89	17.57	17.65	18.43	18.44	17.84
	2039	17.25	16.96	17.14	17.35	17.01	17.03	16.71	17.39	18.09	18.80	18.46	17.75
	2040	17.21	17.10	17.14	17.11	17.05	16.75	16.59	17.23	18.16	18.11	18.24	17.78
	2021	16.43	16.33	16.40	16.45	16.05	15.87	15.66	16.77	18.32	18.57	18.25	17.36
	2022	16.13	16.36	16.68	16.83	16.65	15.91	15.89	16.34	18.02	18.61	18.58	17.50
	2023	16.57	15.99	16.50	16.60	16.06	15.80	15.84	16.99	17.72	18.27	18.50	17.14
	2024	16.52	16.24	16.65	16.85	16.49	16.27	15.77	16.67	18.32	19.03	18.59	17.32
	2025	16.43	16.55	16.77	16.96	16.29	15.55	16.36	16.81	17.64	18.69	18.73	17.43
	2026	16.55	15.98	16.69	16.57	16.34	15.86	16.45	17.26	17.84	19.03	18.55	17.51
	2027	16.48	16.95	17.07	17.02	16.35	16.58	16.09	17.08	18.30	18.77	18.59	17.17
	2028	16.39	16.29	16.79	16.40	15.94	15.75	15.79	16.66	18.19	19.01	18.46	17.33
	2029	16.12	16.17	16.45	16.39	15.80	15.46	15.62	16.92	17.98	18.72	18.45	17.55
Mazo Cruz	2030	16.86	16.57	16.68	16.84	16.77	16.42	16.83	17.14	18.04	18.94	18.87	17.17
	2031	16.28	16.41	16.68	16.53	16.30	16.10	16.15	17.21	18.34	18.97	18.64	17.46
	2032	17.96	18.07	17.19	16.87	16.61	16.78	16.83	17.92	18.57	19.12	18.87	17.35
	2033	16.81	16.50	17.05	16.65	16.37	15.81	15.74	16.92	18.20	19.06	19.19	17.64
	2034	16.36	16.24	16.48	16.83	16.19	15.71	16.31	17.16	18.03	18.90	18.67	17.18
	2035	16.61	16.63	16.76	16.43	16.04	16.01	16.19	17.01	18.39	19.12	18.38	17.33
	2036	16.76	16.40	16.45	16.76	16.01	16.22	16.47	16.78	17.87	18.59	18.48	17.29
	2037	16.65	16.47	16.71	16.95	16.64	16.13	16.29	17.35	18.22	19.02	18.77	17.58
	2038	16.73	16.93	16.81	16.89	16.65	16.37	16.73	17.71	18.12	19.01	19.14	17.53
	2039	16.63	16.43	16.68	16.98	16.57	16.60	16.55	17.46	18.44	19.54	18.67	17.59
	2040	17.08	16.82	16.87	16.57	16.66	16.31	16.50	17.32	18.70	18.72	18.69	17.71
Progreso	2021	16.55	16.50	16.80	16.77	16.42	15.82	15.80	16.63	17.74	17.86	17.77	17.23
	2022	16.43	16.89	16.86	17.10	16.84	16.08	16.10	16.40	17.50	17.86	17.87	17.39

Continuación ...

	2023	16.62	16.36	16.84	16.83	16.44	16.03	15.95	16.85	17.20	17.74	17.99	17.14
	2024	16.69	16.57	16.81	17.10	16.77	16.32	15.94	16.61	17.84	18.37	17.90	17.24
	2025	16.70	16.74	17.13	17.18	16.64	15.85	16.27	16.62	17.14	17.95	17.97	17.30
	2026	16.74	16.60	17.14	16.84	16.65	16.11	16.39	16.93	17.22	18.33	17.77	17.41
	2027	16.88	17.00	17.21	17.22	16.83	16.74	16.24	16.77	17.86	18.26	18.17	17.45
	2028	16.79	16.75	16.92	16.83	16.27	16.04	15.93	16.72	17.78	18.40	17.93	17.36
	2029	16.57	16.41	16.90	16.79	16.23	15.76	15.74	16.71	17.58	17.89	17.77	17.25
	2030	16.99	16.86	17.04	17.37	17.06	16.62	16.74	16.91	17.80	18.23	18.25	17.29
	2031	16.61	16.68	16.99	17.00	16.71	16.34	16.14	16.90	17.75	18.14	18.18	17.50
	2032	17.86	17.91	17.29	17.23	17.17	17.00	16.75	17.67	18.18	18.45	18.34	17.58
	2033	17.02	16.77	17.28	17.06	16.67	16.00	16.01	16.78	17.69	18.32	18.42	17.46
	2034	16.71	16.55	16.83	17.02	16.48	16.06	16.24	16.95	17.61	18.36	18.06	17.33
	2035	16.75	16.82	16.96	16.87	16.46	16.28	16.37	16.97	18.07	18.41	18.03	17.51
	2036	16.95	16.83	16.89	17.11	16.33	16.49	16.38	16.76	17.41	17.88	17.92	17.26
	2037	16.89	16.74	16.94	17.26	16.95	16.41	16.46	17.28	18.01	18.45	18.24	17.51
	2038	17.04	17.14	17.21	17.20	16.88	16.63	16.79	17.33	17.59	18.32	18.35	17.58
	2039	16.88	16.79	17.07	17.28	16.91	16.92	16.57	17.28	17.94	18.75	18.19	17.57
	2040	17.10	16.97	16.99	16.88	16.96	16.60	16.49	17.10	18.09	17.99	18.12	17.52
	2021	16.95	16.72	16.90	16.94	16.59	15.91	15.74	16.67	18.06	18.43	18.27	17.62
	2022	16.76	17.00	17.16	17.35	17.03	16.11	16.05	16.33	17.89	18.30	18.41	17.80
	2023	17.10	16.70	17.05	17.07	16.48	16.00	15.97	16.97	17.50	18.11	18.45	17.55
	2024	17.09	16.83	17.20	17.27	16.83	16.40	15.93	16.70	18.24	18.82	18.48	17.75
Pucara	2025	17.07	17.16	17.27	17.49	16.72	15.68	16.32	16.71	17.53	18.46	18.50	17.76
	2026	17.07	16.64	17.32	17.13	16.83	16.01	16.52	17.12	17.54	18.76	18.49	18.05
	2027	17.19	17.57	17.55	17.58	16.87	16.81	16.30	16.90	18.25	18.72	18.64	17.84
	2028	17.20	17.01	17.27	17.09	16.45	16.04	15.93	16.75	18.15	18.91	18.53	17.83
	2029	16.73	16.62	17.09	17.07	16.43	15.78	15.68	16.76	17.75	18.32	18.30	17.87

Continuación ...

2030	17.32	17.08	17.39	17.51	17.15	16.60	16.76	17.11	18.07	18.72	18.78	17.75
2031	16.88	17.03	17.34	17.26	16.84	16.43	16.09	17.06	18.17	18.77	18.67	18.09
2032	18.59	18.59	17.72	17.44	17.25	17.09	16.83	17.96	18.71	19.07	18.91	18.02
2033	17.40	17.14	17.65	17.47	16.87	16.03	16.02	16.86	18.12	18.79	19.00	17.97
2034	16.91	16.79	16.95	17.31	16.58	16.00	16.30	17.09	17.94	18.78	18.61	17.74
2035	17.16	17.27	17.38	17.05	16.47	16.30	16.31	17.01	18.54	18.92	18.45	17.87
2036	17.37	17.16	17.13	17.34	16.48	16.50	16.40	16.77	17.71	18.30	18.51	17.84
2037	17.16	16.94	17.23	17.48	17.08	16.46	16.54	17.39	18.20	18.78	18.84	17.99
2038	17.32	17.44	17.31	17.42	17.03	16.58	16.76	17.55	17.98	18.75	18.88	18.12
2039	17.30	17.06	17.22	17.52	17.04	16.94	16.65	17.51	18.30	19.26	18.81	18.01
2040	17.67	17.61	17.52	17.25	17.05	16.62	16.53	17.19	18.56	18.42	18.66	18.24
