

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**



**ESTIMACIÓN DE VARIABLES CLIMÁTICAS MEDIANTE UNA
INTERPOLACIÓN ESPACIALMENTE DISTRIBUIDA**

POR

NOLBERTO IGNACIO GUZMÁN CHÁVEZ

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO.**

**CHILLÁN – CHILE
2024**

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**

**ESTIMACIÓN DE VARIABLES CLIMÁTICAS MEDIANTE UNA
INTERPOLACIÓN ESPACIALEMENTE DISTRIBUIDA**

POR

NOLBERTO IGNACIO GUZMÁN CHÁVEZ

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO.**

**CHILLÁN – CHILE
2024**

Aprobada por:

Profesor Asistente, Mathias Kuschel O.
Ing. Civil Agrícola, Dr.

Guía

Profesor Asociado, Arturo Calderón O.
Ing. Agrónomo, Ph. D.

Asesor

Profesor Asistente, Walter Valdivia C.
Ing. Agrónomo, Dr.

Asesor

Profesor Asociado, Guillermo Wells M.
Ing. Agrónomo, Mg. Cs.

Decano

TABLA DE CONTENIDOS

	Página
Resumen	1
Summary.....	2
Introducción	2
Materiales y Métodos	4
Resultados y Discusión	10
Conclusiones	21
Referencias	22

INDICE DE FIGURAS Y TABLAS

	Página
Figura 1 Distribución Espacial de Estaciones Meteorológicas desde Valparaíso hasta La Araucanía.....	5
Figura 2 Segunda sección de proceso de datos a interpolar: (A) Selección de estaciones y su ubicación geográfica; y (B) Recopilación de datos de la variable climática.....	7
Figura 3 Visualización de la red de Estaciones Meteorológicas para la región de Valparaíso mediante un polígono de área estimada.....	8
Figura 4 Gráficos de dispersión 1:1 de la temperatura mínima (Tmin), promedio (Tmed) y máxima (Tmax) y la humedad relativa mínima (HRmin), media (HRmed) y máxima (HRmax) para las regiones de Valparaíso, Metropolitana, O'Higgins y Maule.....	13
Figura 5 Gráficos de dispersión 1:1 de la temperatura mínima (Tmin), promedio (Tmed) y máxima (Tmax) y la humedad relativa mínima (HRmin), media (HRmed) y máxima (HRmax) para las regiones de Ñuble, Biobío y La Araucanía.....	14
Figura 6 Gráficos de dispersión 1:1 de la radiación solar (Rs), velocidad del viento (u_2), precipitación acumulada (PP), Evapotranspiración de referencia (ET _o) y Evapotranspiración de referencia acumulada semanal (ET _o 7) para las regiones de Valparaíso, Metropolitana, O'Higgins y Maule.....	16
Figura 7 Gráficos de dispersión 1:1 de la radiación solar (Rs), velocidad del viento (u_2), precipitación acumulada (PP), Evapotranspiración de referencia (ET _o) y Evapotranspiración de referencia acumulada semanal (ET _o 7) para las regiones de Ñuble, Biobío y Araucanía....	17

Tabla 1	Abreviaturas y nombres completos de las regiones.....	5
Tabla 2	Distancia de Estaciones Meteorológicas respecto a la Estación de Referencia (km).....	6
Tabla 3	Criterios de evaluación del NRMSE.....	9
Tabla 4	Valores de NRMSE por región y variable climática: Resumen general.....	10

ESTIMACIÓN DE VARIABLES CLIMÁTICAS MEDIANTE UNA INTERPOLACIÓN ESPACIALMENTE DISTRIBUIDA

ESTIMATION OF CLIMATIC VARIABLES THROUGH SPATIALLY DISTRIBUTED INTERPOLATION

Palabras índice adicionales: Interpolación 3D, evapotranspiración de referencia, estaciones meteorológicas, Matlab, análisis geoespacial.

RESUMEN

La agricultura moderna depende de datos climáticos precisos para optimizar el riego y la productividad de los cultivos, sin embargo, la limitada red de estaciones meteorológicas y los nulos datos entregados por estas en algunas áreas de Chile dificulta la obtención de información necesaria para llevar a cabo actividades agrícolas. Esta investigación evalúa una metodología de interpolación para estimar variables climáticas en siete regiones de alta producción agrícola con escasa cobertura de estaciones meteorológicas. Se utilizaron datos diarios de 40 estaciones meteorológicas entre 2018 y 2022, procesados con un código en MATLAB para realizar interpolaciones tridimensionales, integrando las coordenadas de latitud, longitud y los valores de la variable climática a interpolar. La precisión se evaluó mediante NRMSE y gráficos de dispersión 1:1. Los resultados muestran una buena precisión general en la mayoría de las variables, destacando la evapotranspiración de referencia con un NRMSE entre 7,32% y 13,51%, mientras que la interpolación para precipitación y velocidad del viento presentó resultados inaceptables. La metodología demuestra ser efectiva para mejorar la disponibilidad de datos climáticos en áreas con deficiencia de estaciones meteorológicas, facilitando una gestión más eficiente del agua en la agricultura al optimizar las estrategias de riego y reducir el desperdicio de recursos hídricos.

SUMMARY

Modern agriculture depends on accurate climatic data to optimize irrigation and crop productivity; however, the limited network of weather stations and the lack of data provided by them in some areas of Chile makes it difficult to obtain the information needed to carry out agricultural activities. This research evaluates an interpolation methodology to estimate climatic variables in seven regions of high agronomic production with low meteorological station coverage. Daily data from 40 meteorological stations between 2018 and 2022 were, processed with a code in MATLAB to perform three-dimensional interpolations, integrating the coordinates of latitude, longitude and the values of the climatic variable to be interpolated. Accuracy was evaluated using NRMSE and scatter plots. The results show a good overall accuracy for most variables, highlighting the reference evapotranspiration with a NRMSE between 7.32% and 13.51%, while the interpolation for precipitation and wind speed presented unacceptable results. The methodology proves to be effective in improving the availability of climate data in areas with a deficiency of meteorological stations, facilitating more efficient water management in agriculture by optimizing irrigation strategies and reducing the waste of water resources.

INTRODUCCIÓN

La agricultura emplea diversas técnicas para establecer cultivos adaptados a las condiciones fisicoquímicas del suelo y a las circunstancias climáticas de la zona (Casas, 2012). Con el avance tecnológico, se han desarrollado metodologías que ayudan a los agricultores a tomar decisiones que afectan los parámetros productivos de los cultivos, especialmente ante la variabilidad climática y la alta demanda hídrica en zonas con baja disponibilidad de agua para la agricultura (Vicuña y Dracup, 2007).

Por esta razón, han surgido sistemas que permiten optimizar las operaciones agrícolas mediante el uso de maquinarias, insumos y avances tecnológicos. Uno de los factores claves es la disponibilidad de información meteorológica periódica. En este contexto, las estaciones meteorológicas automáticas (EMA) realizan un papel

fundamental, ya que están diseñadas para proporcionar datos esenciales como la temperatura, humedad relativa, precipitación acumulada, velocidad del viento, radiación solar y evapotranspiración de referencia. Estos datos son fundamentales para el establecimiento óptimo de cultivos, especialmente en la implementación de agricultura de precisión (Sepúlveda, 2020). En la actualidad, en Chile existen diversas redes de estaciones meteorológicas que permiten la obtención automática de esta información periódica. Entre estas redes se encuentran el Instituto de Investigaciones Agropecuarias (INIA), el Centro de Ciencia del Clima y la Resiliencia (CR2), la Dirección General de Aguas (DGA), la Dirección Meteorológica de Chile (DMC), entre otras. La red del INIA es una de las más importantes para el área agronómica, con más de 300 estaciones distribuidas a lo largo del territorio nacional que brindan información a través de su base de datos (INIA, 2024).

Las variables proporcionadas por estos instrumentos representan una fuente potencialmente valiosa de información para la gestión de los recursos hídricos (Silva *et al.*, 2010). Éstas permiten una adecuada reposición del agua en los cultivos, ajustada a sus necesidades específicas, y, en consecuencia, una frecuencia de riego óptima. Este aspecto es particularmente relevante dado que la agricultura de regadío es uno de los mayores consumidores de agua (Ward y Trimble, 2004). En Chile, el 73% del recurso hídrico disponible se destina a este sector, lo que permite regar aproximadamente 902.158 hectáreas (ODEPA, 2022).

La agricultura, al ser el principal usuario del recurso hídrico, enfrenta desafíos significativos debido a la escasez y baja disponibilidad de agua, lo que impacta el desarrollo sostenible del país y sus procesos agroalimentarios (ODEPA, 2022). En Chile, este problema se ha visto agravado por una disminución en las precipitaciones desde el año 2010, con una reducción que oscila entre el 25% y el 45% (Garreaud *et al.*, 2017). La disponibilidad limitada de agua condiciona las decisiones sobre manejo y técnicas de riego, y un uso inapropiado de este recurso puede provocar escasez a corto o largo plazo, así como la degradación de suelos, afectando negativamente su estructura y capacidad de retención de nutrientes, y repercutiendo finalmente en la productividad de los cultivos (Pereira *et al.*, 2009).

A pesar de la implementación de instrumentos para la obtención de información meteorológica, es común enfrentar la falta de datos debido a problemas de comunicación entre los instrumentos, fallas externas provocadas por animales, golpes en los sensores, o la limitada disponibilidad de estaciones cercanas (Antúnez *et al.*, 2013). Cuando se requieren datos para establecer un proyecto de cultivo específico y se presentan estos problemas, se debe estimar la información utilizando estaciones meteorológicas cercanas y los informes obtenidos de ellas.

Uno de los enfoques para estimar datos es la interpolación, definida como “el proceso de utilizar dos o más puntos con valores conocidos para estimar los valores en otros puntos” (Chang, 2006). En meteorología, se emplean varios métodos de interpolación, como la interpolación espacial, TIN (Triangulated Irregular Network), temporal, Kriging e IDW (Inverse Distance Weighted), entre otros. Cada uno de estos métodos estima datos mediante diferentes análisis basados en estructuras de geoestadística. Estos métodos resultan especialmente útiles para abordar la falta de datos necesarios para la agricultura y la estimación de las necesidades hídricas de los cultivos.

El objetivo de esta investigación fue desarrollar y evaluar una metodología de interpolación empleando estaciones meteorológicas ubicadas en distintas zonas de alta producción agrícola en Chile. Se compararon los datos obtenidos a través de la interpolación con los datos de referencia disponibles en la página de agrometeorología INIA, utilizando indicadores específicos para determinar la precisión y eficacia de la metodología propuesta.

MATERIALES Y MÉTODOS

Datos de las estaciones meteorológicas

Se descargaron datos observados diarios de las siguientes variables climáticas: temperatura mínima (Tmin), temperatura promedio (Tmed), temperatura máxima (Tmax), humedad relativa mínima (HRmin), humedad relativa promedio (HRmed), humedad relativa máxima (HRmax), radiación solar (Rs), velocidad del viento (u_2), precipitación (Pp), y evapotranspiración de referencia (ETo). Estos datos fueron

registrados desde el 1 de enero de 2018 hasta el 31 de diciembre de 2022 en estaciones meteorológicas ubicadas desde la región de Valparaíso hasta La Araucanía en el territorio nacional (Figura 1). La información fue extraída de la página web de Agrometeorología del Instituto Nacional de Investigación Agropecuaria (INIA) y comprende datos de 40 estaciones, los cuales fueron posteriormente procesados utilizando un entorno de programación.

Figura 1. Distribución Espacial de Estaciones Meteorológicas desde Valparaíso hasta La Araucanía.

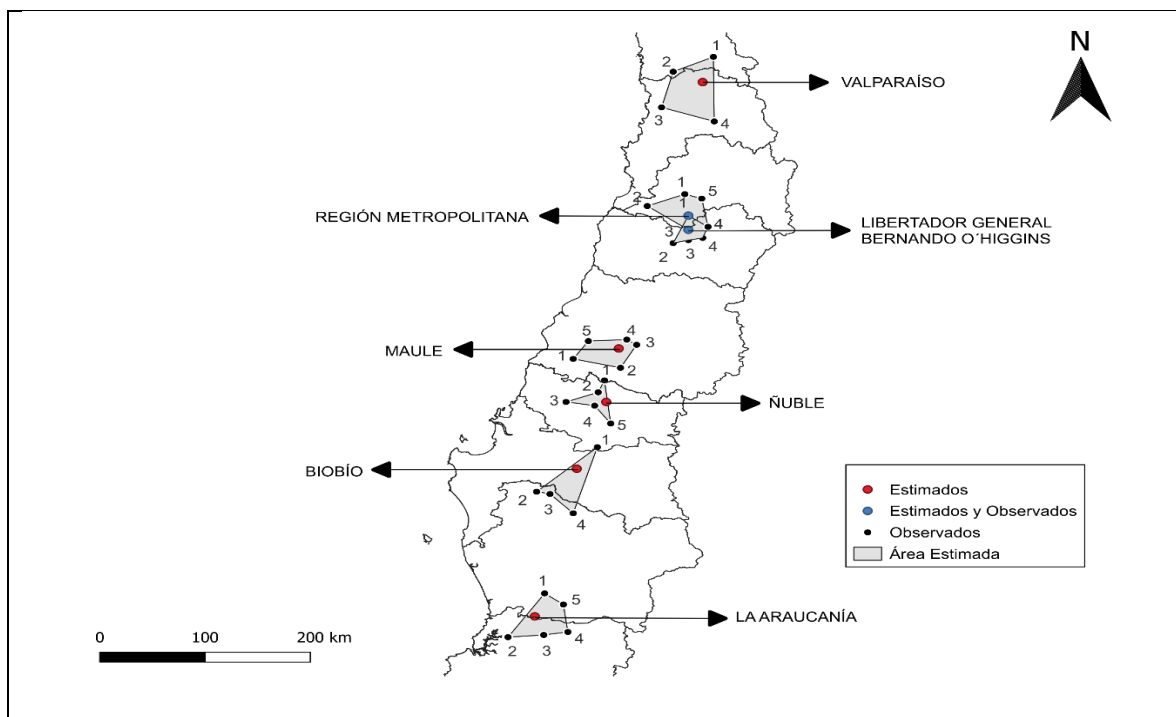


Tabla 1. Abreviaturas y nombres completos de las regiones.

Abreviatura	Región
VA	Valparaíso
RM	Región Metropolitana
LI	Libertador General Bernardo O'Higgins
ML	Maule
NB	Ñuble
BI	Biobío
AR	La Araucanía

La siguiente tabla muestra las distancias, expresadas en kilómetros, de cada una de las estaciones meteorológicas utilizadas en la interpolación con respecto a la estación de referencia. Esta información es esencial para comprender la variabilidad en la precisión de la interpolación.

Tabla 2. Distancia de Estaciones Meteorológicas respecto a la Estación de Referencia (km).

Región	DE1	DE2	DE3	DE4	DE5
VA	39,37	34,79	57,40	60,03	-
RM	32,38	44,90	21,08	26,25	29,04
LI	21,08	25,37	15,53	19,13	20,76
ML	48,60	28,91	18,91	15,61	32,69
NB	32,23	16,53	40,30	12,89	32,49
BI	38,10	52,57	46,11	66,69	-
AR	35,70	40,39	29,06	39,44	32,81

DE1: Distancia Estación 1; DE2: Distancia Estación 2; DE3: Distancia Estación 3; DE4: Distancia Estación 4; DE5: Distancia Estación 5.

Código de interpolación de variables climáticas

Se desarrolló un código en el entorno de programación MATLAB, cuyo objetivo fue realizar una interpolación 3D de las variables climáticas extraídas. El código utilizó latitud, longitud y los datos de la variable a interpolar. Para ello, fue necesario disponer estos datos en formato ".xlsx", así como las ubicaciones de las estaciones meteorológicas seleccionadas.

El código se estructura en dos partes para mejorar la eficiencia, rapidez y organización del proceso. La primera parte implica la ejecución del código, que requiere seleccionar el archivo de la variable climática a interpolar. La primera fila de este archivo contiene los nombres de las estaciones meteorológicas, actuando como encabezado de columna, mientras que, a partir de la segunda fila, cada columna bajo el encabezado de las estaciones incluye los datos del período registrado. Además, se debe seleccionar el archivo que contiene las ubicaciones de las estaciones, proporcionando las coordenadas de latitud y longitud

correspondientes. Esta información permite vincular y ubicar cada estación con sus datos climáticos asociados.

Mediante un bucle, es decir, un proceso que permite realizar acciones reiterativas, se activa una sección que procesó los datos de los archivos seleccionados. El algoritmo recorrió las fechas, las estaciones y los datos de la variable climática seleccionada, vinculándolos a las coordenadas de latitud y longitud de las estaciones meteorológicas (Figura 2). El objetivo fue realizar un análisis espacialmente distribuido para obtener estimaciones de estas variables en zonas geográficas donde no se encontraban estaciones meteorológicas. En este análisis, los datos de las estaciones se consideraron continuos, mientras que las estimaciones en las áreas sin estaciones se trataron como datos discontinuos.

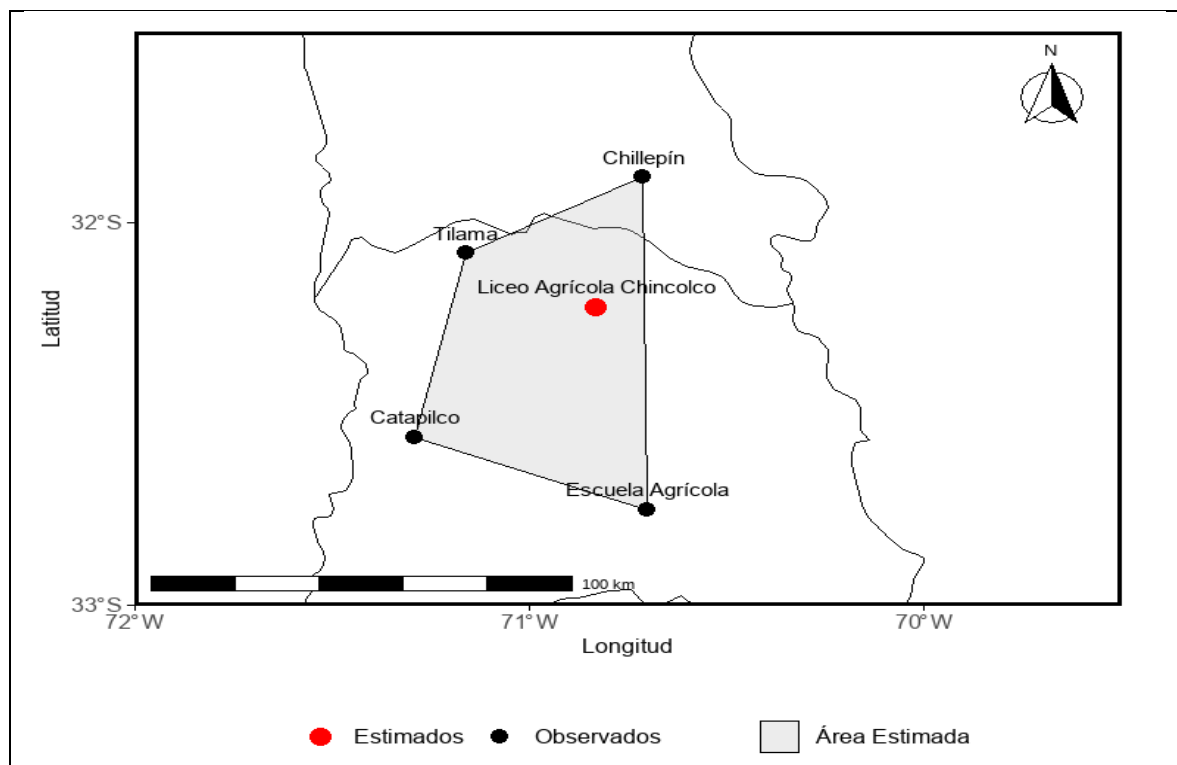
Se genera una cuadrícula tridimensional en donde las coordenadas se definieron como “x” para latitud, “y” para longitud, y “v” para los valores de la variable climática. Posteriormente, se interpolan los datos en la cuadrícula, formando un polígono donde cada vértice representa una estación meteorológica (Figura 2). De esta manera, se obtienen los datos estimados dentro de la figura geométrica generada.

Figura 2. Segunda sección de proceso de datos a interpolar: (A) Selección de estaciones y su ubicación geográfica; y (B) Recopilación de datos de la variable climática.

A	1	2	3	4	B	578	10.4000	8.9000	8.8000	9
1	Estación/Ubicación	Latitud	Longitud	Elevación	579	14.1000	12.8000	8.5000	10.8000	
2	Liceo Agrícola Chincolco				580	19.6000	15.2000	10.2000	14.5000	
3	Chillepín				581	19.6000	16.6000	11	16.2000	
4	Tilama				582	14	10.4000	12	12	
5	Catapilco				583	9.3000	9.4000	9	10.6000	
6	Escuela Agrícola				584	9.9000	7.8000	7.6000	9.7000	
7	El Asiento				585	7	6.4000	5.4000	6.8000	
8	San Antonio de Naltahua				586	7.2000	6.4000	5	8	
9	San Pedro de Melipilla				587	14.3000	10	8.4000	11.2000	
10	Valdivia de Paine				588	11.2000	8.9000	8.1000	10.3000	

El resultado puede contener valores no válidos (NaN) cuando no se puede formar el polígono, debido a que hay menos de tres estaciones meteorológicas disponibles o no se dispone de datos de la variable climática seleccionada.

Figura 3. Visualización de la red de Estaciones Meteorológicas para la región de Valparaíso mediante un polígono de área estimada.



Métodos de evaluación de resultados

Posterior a la interpolación 3D de las variables climáticas realizada mediante el código desarrollado, se realizó una evaluación en la precisión de los resultados utilizando dos indicadores principales: la Raíz Cuadrada del Error Cuadrático Medio Normalizado (NRMSE, por sus siglas en inglés) y gráficos de dispersión 1:1.

Se empleó el NRMSE para cuantificar la exactitud de los datos estimados en comparación con los datos de referencia. Para calcular el NRMSE, primero se utilizó la ecuación de la Raíz Cuadrada del Error Medio (RMSE), aplicando posteriormente la ecuación de normalización. La ecuación del RMSE es la siguiente:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (1)$$

Donde, \hat{y}_i son los datos observados, y_i son los datos estimados y n es el número total de datos observados.

Luego, se utilizó la ecuación de NRMSE correspondiente:

$$NRMSE = \left(\frac{RMSE}{\bar{y}_i} \right) \times 100 \quad (2)$$

Donde, \bar{y}_i es el valor promedio de los datos observados.

Para interpretar los resultados del NRMSE, se aplicaron los siguientes criterios de evaluación de acuerdo con Jamieson *et al.*, (1991) (Tabla 3):

Tabla 3. Criterios de evaluación del NRMSE.

Criterios de evaluación NRMSE	
NRMSE	Clasificación
< 10%	Excelente
10 – 20%	Bueno
20 – 30%	Aceptable
> 30%	Inaceptable

Adicionalmente, se realizaron gráficos de dispersión para complementar la evaluación cuantitativa del NRMSE. Estos gráficos permiten visualizar la relación entre los datos observados y los datos estimados, facilitando la identificación de patrones, correlaciones y posibles discrepancias. Asimismo, las representaciones gráficas ayudan a detectar si existe una tendencia a sobrestimar o subestimar los datos estimados y en qué medida ocurre.

Ajuste lineal de los datos estimados

Para mejorar la precisión de los datos estimados con respecto a los datos obtenidos, se realizó un ajuste lineal utilizando la pendiente y la intersección de la correlación entre los datos observados y estimados. El cual se realizó mediante la siguiente ecuación:

$$VA = m \times VE + n \quad (3)$$

Donde, VA es el valor ajustado, m es la pendiente, VE son los valores estimados y n es la intersección de la recta.

RESULTADOS Y DISCUSIÓN

Análisis cuantitativo (NRMSE)

Tabla 4. Valores de NRMSE por región y variable climática: Resumen general.

VARIABLE	NRMSE						
	REGIÓN						
	VA	RM	LI	ML	NB	BI	AR
Tmin (°C)	50,8	19,37	16,37	11,72	26,33	14,23	23,12
Tmed (°C)	10,62	4,94	6,01	4,22	6,33	5,07	6,77
Tmax (°C)	23,06	4	6,25	3,91	3,84	4,42	4,49
HRmin (%)	28,8	20,86	20,43	17,21	10,15	16,02	13,18
HRmed (%)	8,27	6,86	5,3	5,03	5,38	3,65	5,01
HRmax (%)	10,3	5,87	4,72	4,66	3,91	4,68	3,25
Rs (Mj/m ²)	40,36	9,65	14,24	12,89	15,52	10,09	12,82
u ₂ (km/hr)	21,42	20,51	26,73	20,79	29,12	22,38	34,43
Pp (mm)	297,14	115,99	140,97	94,46	227,76	167,39	93,12
ETo (mm)	10,01	7,32	8,67	10,08	12,9	10,33	13,51
ETo7 (mm)	6,12	5,33	4,95	7,66	8,81	6,66	8,6

T_{mín}: Temperatura mínima; T_{med}: Temperatura promedio; T_{max}: Temperatura máxima; HR_{mín}: Humedad relativa mínima; HR_{med}: Humedad relativa promedio; HR_{máx}: Humedad relativa máxima; R_s: Radiación Solar; u₂: Velocidad viento; P_p: Precipitación acumulada; E_{To}: Evapotranspiración de referencia; E_{To7}: Evapotranspiración de referencia cada 7 días.

Temperatura mínima (T_{mín}). El modelo presentó una precisión inaceptable en la región de Valparaíso, con un NRMSE de 50,8%. En contraste, Ñuble y La Araucanía mostraron una precisión aceptable, con NRMSE de 26,33% y 23,12%, respectivamente. Por su parte, las regiones Metropolitana, O'Higgins, Biobío y Maule alcanzaron una buena precisión, con NRMSE entre 19,37% y 11,72%.

Temperatura promedio (T_{prom}). Se observa un desempeño excelente en la mayoría de las regiones, con valores de NRMSE entre 4,22 y 10,62%. Valparaíso obtuvo un 10,62%, clasificado como bueno, mientras que las demás regiones se mantuvieron en el rango de excelente.

Temperatura máxima (T_{máx}). A excepción de Valparaíso, se obtuvieron resultados excelentes, con un NRMSE por debajo del 10%, oscilando entre 3,25% y 9,31%. Valparaíso, con un NRMSE de 10,3%, se clasificó como bueno.

Humedad relativa mínima (HR_{mín}). Las regiones de Valparaíso, Metropolitana y O'Higgins se clasificaron como aceptables con un NRMSE superior al 20%. En contraste, las regiones de Maule, Ñuble, Biobío y La Araucanía presentaron una buena exactitud con valores entre 10,15% y 17,21%.

Humedad relativa promedio (HR_{prom}). Todas las regiones presentaron una precisión de interpolación excelente para esta variable, con NRMSE entre 3,65% (Biobío) y 8,27% (Valparaíso).

Humedad relativa máxima (HR_{máx}). La interpolación fue excelente en la mayoría de las regiones, con un NRMSE que varió entre 3,25% y 10,3%. Valparaíso, con un 10,3%, se clasificó como buena, mientras que La Araucanía obtuvo el valor más bajo con un NRMSE de 3,25%.

Radiación solar (R_s). La mayoría de las regiones mostraron una buena precisión de interpolación, con cinco regiones obteniendo un NRMSE entre 10,09% y 15,52%. La Región Metropolitana se destacó con un resultado excelente de 9,65%. En contraste, Valparaíso obtuvo un resultado inaceptable con un 40,36%.

Velocidad del viento (u₂). La exactitud de interpolación fue aceptable en 6 regiones, con un NRMSE entre 20,51% y 29,12%. Araucanía, con 34,43%, se clasificó como inaceptable.

Precipitación acumulada (PP). Los valores de NRMSE para la precipitación fueron inaceptables en todas las regiones, con Valparaíso obteniendo el valor más alto de 297,14%. Las regiones Metropolitana, O'Higgins, Maule, Ñuble, Biobío y Araucanía también mostraron valores sobre un 90%.

Evapotranspiración de referencia (E_{To}). La precisión de interpolación fue excelente y buena en todas las regiones. La región Metropolitana obtuvo el valor más bajo con un 7,32%, clasificándose como excelente, mientras que La Araucanía alcanzó el valor más alto con un 13,51%, clasificándose como buena.

Evapotranspiración de referencia para 7 días (ET_o 7). La precisión de interpolación fue excelente en todas las regiones, con un NRMSE entre 4,95% y 8,6%.

Análisis cualitativo (Gráficos de dispersión 1:1)

Temperatura mínima (T_{min}). En las regiones Metropolitana, O'Higgins, Maule, Ñuble, Biobío y La Araucanía, los datos estimados muestran una buena correlación con los observados, sin grandes desviaciones aparentes (Figura 4 y Figura 5). Mientras que en la región de Valparaíso se observa una sobrestimación de datos con temperaturas menores a 5°C, y una subestimación sobre los 10°C (Figura 3).

Temperatura media (T_{med}). Los gráficos (Figura 4 y Figura 5) muestran una excelente correlación en todas las regiones, con los puntos agrupándose estrechamente alrededor de la línea, lo que indica que los datos estimados se alinean muy bien con los datos observados.

Temperatura máxima (T_{max}). La región de Valparaíso presenta una subestimación de datos con temperaturas bajo los 25°C aprox., y una subestimación sobre los 25°C (Figura 4). Las demás regiones demostraron una alta precisión en los valores estimados (Figura 4 y Figura 5).

Humedad relativa mínima (HR_{min}). En las regiones de Valparaíso, Metropolitana, O'Higgins, Maule y Biobío, se observa una tendencia a subestimar los datos en torno al 50-60% de HR (Figura 4 y Figura 5). Por otro lado, en las regiones de Ñuble y La Araucanía, esta subestimación no se presenta. Sin embargo, en La Araucanía, los datos muestran una mayor dispersión (Figura 5).

Humedad relativa media (HR_{med}). En todas las regiones se observa una excelente correlación general. Sin embargo, se identificó cierta dispersión de algunos datos en las regiones del Maule y La Araucanía (Figura 4 y Figura 5).

Humedad relativa máxima (HR_{max}). Se observa una sobrestimación en el rango de 50-60% de HR_{max} en todas las regiones (Figura 4 y Figura 5). No obstante, a

medida que los valores se acercan al 100%, los datos estimados se alinean progresivamente con los datos observados.

Figura 4. Gráficos de dispersión 1:1 de la temperatura mínima (Tmin), promedio (Tmed) y máxima (Tmax) y la humedad relativa mínima (HRmin), media (HRmed) y máxima (HRmax) para las regiones de Valparaíso, Metropolitana, O'Higgins y Maule.

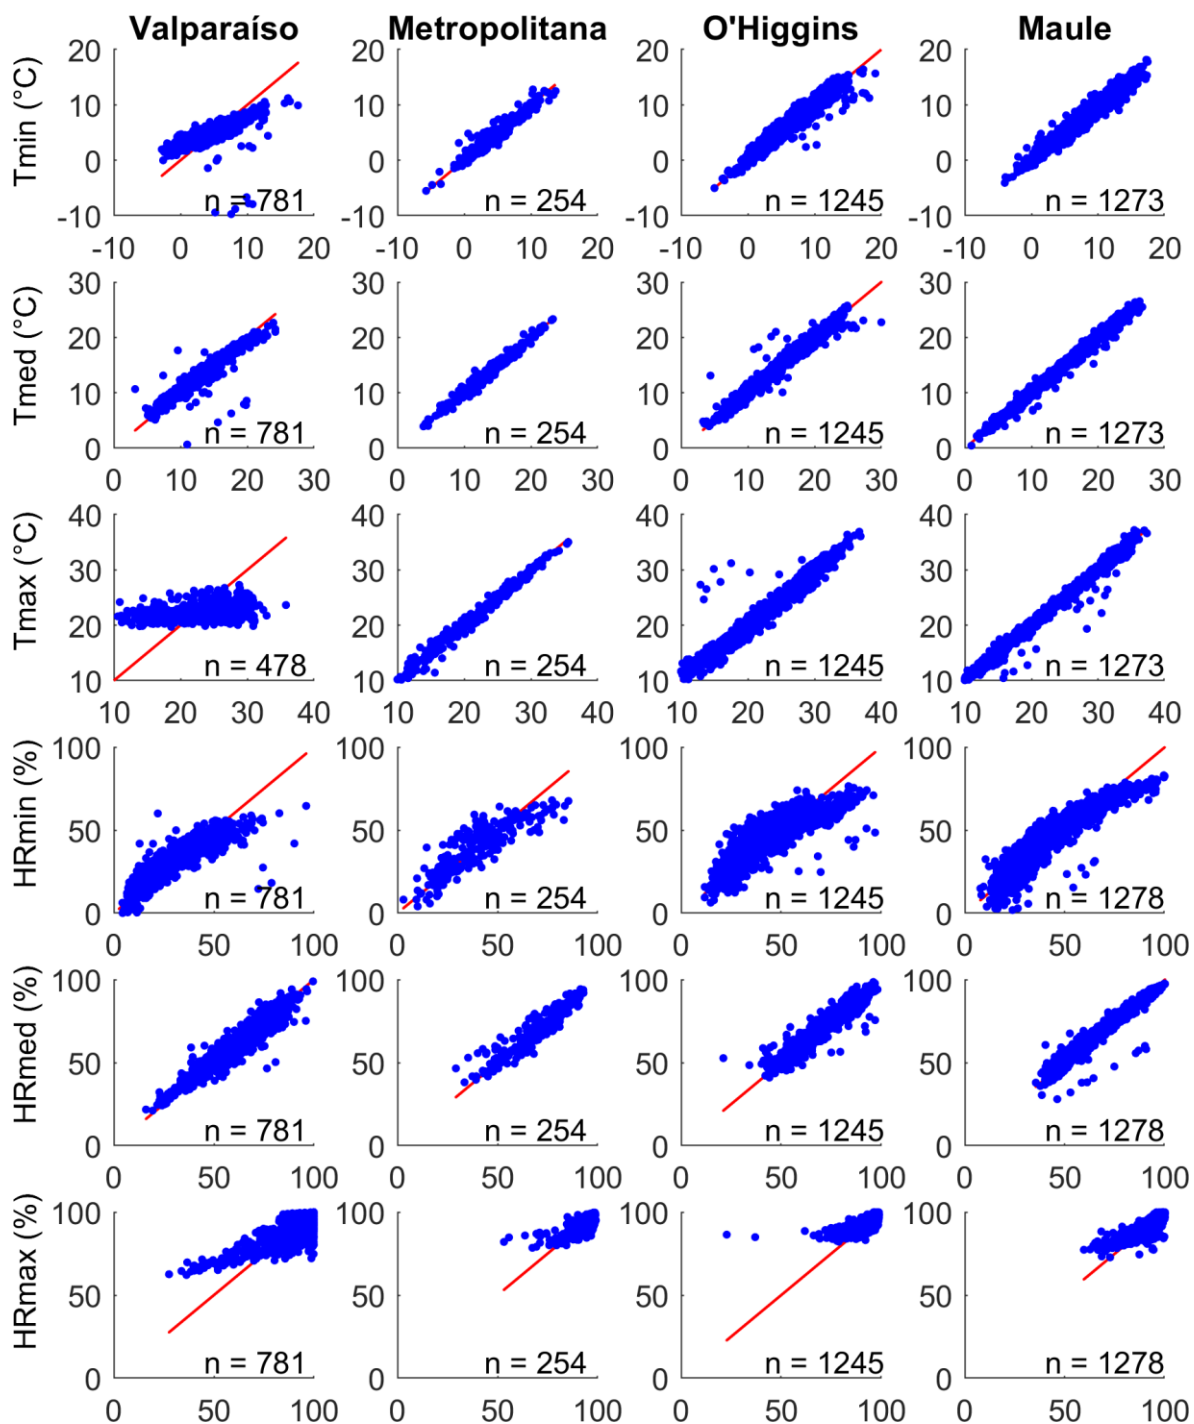



Figura 5. Gráficos de dispersión 1:1 de la temperatura mínima (Tmin), promedio (Tmed) y máxima (Tmax) y la humedad relativa mínima (HRmin), media (HRmed) y máxima (HRmax) para las regiones de Ñuble, Biobío y La Araucanía.



Radiación solar (Rs). En la región de Valparaíso, se observa una subestimación en los valores inferiores a 20 MJ/m², mientras que en los valores superiores se

registra una sobreestimación. Esto indica que no se logran capturar con precisión ni los valores más bajos ni los más altos en esta área (Figura 6). En contraste, las regiones Metropolitana, O'Higgins, Maule, Ñuble, Biobío y La Araucanía presentan una buena correlación entre los datos estimados y los datos observados (Figura 6 y Figura 7). Sin embargo, en las regiones de O'Higgins, Maule y Ñuble, se identifican algunos datos dispersos que se encuentran fuera de la tendencia general del resto de los datos.

Velocidad del viento (u_2). En O'Higgins, la estimación presenta desviaciones significativas, con claras sobreestimaciones y subestimaciones (Figura 6). En las demás regiones, aunque los datos estimados siguen los patrones de los observados, la dispersión es considerable, formando una banda amplia en lugar de una línea precisa, lo que refleja una variabilidad en la precisión de las estimaciones (Figura 6 y Figura 7).

Precipitación acumulada (PP). La estimación de la precipitación muestra un patrón similar de variabilidad. En la región de O'Higgins, se observan tanto sobreestimaciones como subestimaciones marcadas (Figura 6). En las demás regiones, aunque las estimaciones siguen el patrón general de los datos observados, la dispersión es considerable, formando una banda ancha. Esto sugiere que, si bien la tendencia general es capturada, la precisión en la estimación de la precipitación varía significativamente entre las diferentes regiones (Figura 6 y Figura 7).

Los datos están más concentrados en valores bajos de precipitación, pero la alineación cercana a la línea de referencia indica que incluso en valores altos, la estimación sigue siendo razonablemente precisa.

Evapotranspiración de referencia (ET_o). En todas las regiones, los datos estimados se alinean bien con los observados, lo que refleja una alta precisión en la estimación de la evapotranspiración de referencia (Figura 6 y Figura 7). No obstante, en Ñuble y La Araucanía, los valores dentro del rango de 9-10 mm de ET_o tienden a mostrar cierta dificultad para alcanzar las estimaciones más altas (Figura 7).

Evapotranspiración de referencia acumulada semanal (ETo 7). Se observa una excelente correlación en todas las regiones (Figura 6 y Figura 7). En Valparaíso, Metropolitana, O'Higgins y Maule, los datos estimados coinciden de forma muy precisa con la línea de los datos observados (Figura 6). En cambio, en Ñuble, Biobío y La Araucanía, los valores dentro del rango de 45-50 mm presentan cierta limitación para ajustarse a las estimaciones más altas (Figura 7).

Figura 6. Gráficos de dispersión 1:1 de la radiación solar (R_s), velocidad del viento (u_2), precipitación acumulada (PP), Evapotranspiración de referencia (ETo) y Evapotranspiración de referencia acumulada semanal (ETo 7) para las regiones de Valparaíso, Metropolitana, O'Higgins y Maule.

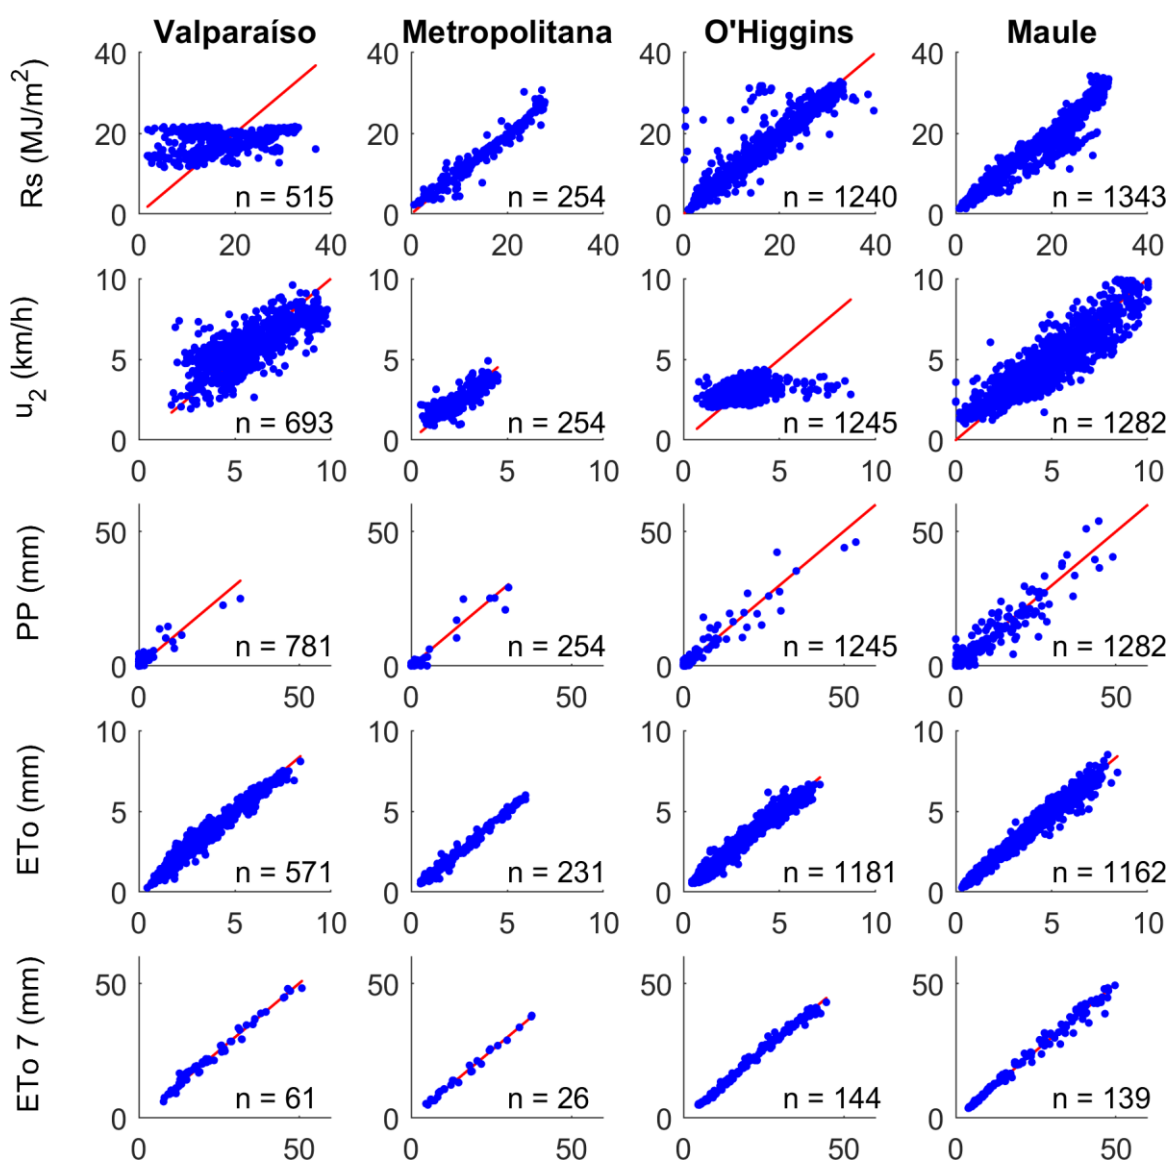
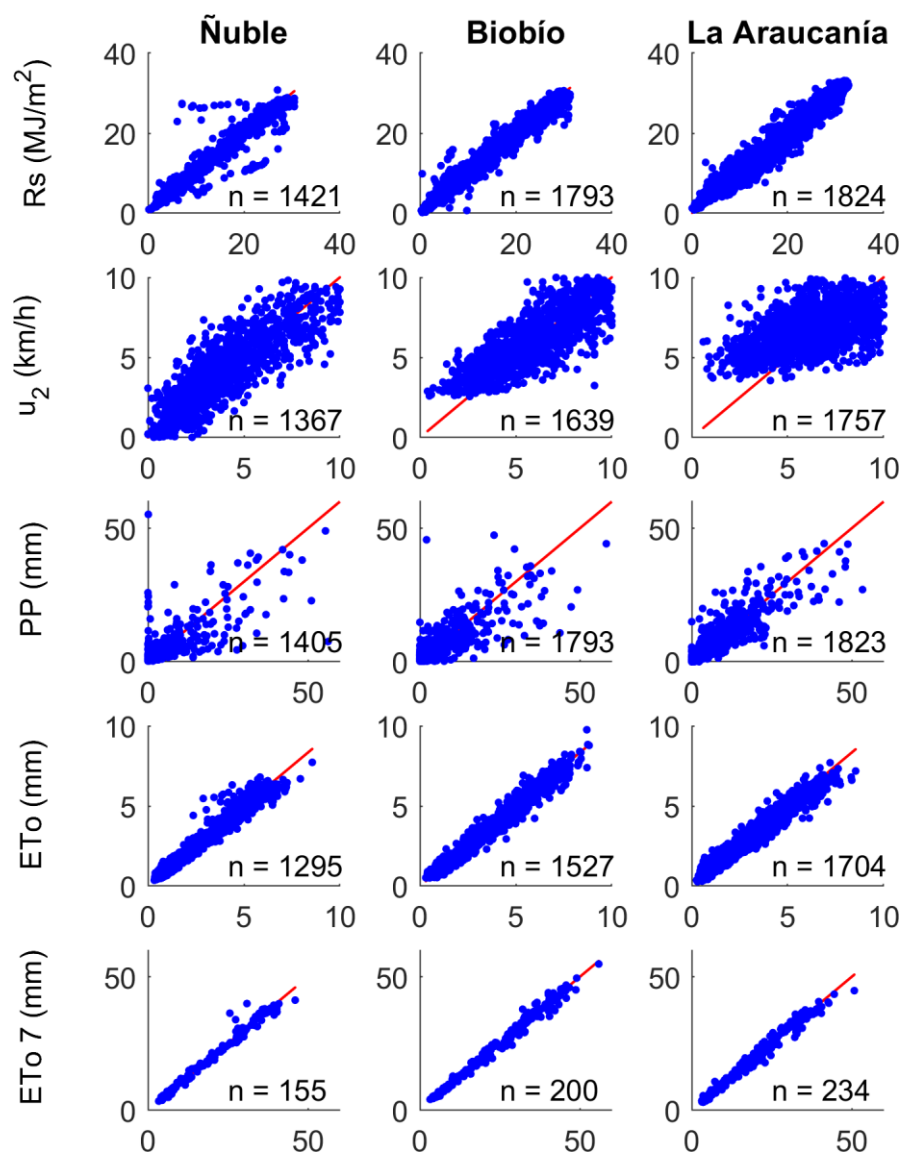


Figura 7. Gráficos de dispersión 1:1 de la radiación solar (R_s), velocidad del viento (u_2), precipitación acumulada (PP), Evapotranspiración de referencia (ETo) y Evapotranspiración de referencia acumulada semanal (ETo 7) para las regiones de Ñuble, Biobío y Araucanía.



Los resultados del análisis cuantitativo revelan variaciones significativas en la precisión de la interpolación de diferentes variables climáticas según la región. La interpolación de la temperatura mínima (T_{min}) mostró un desempeño inaceptable en Valparaíso, en contraste con las demás regiones que variaron de buena a aceptable. Por otro lado, la temperatura promedio (T_{med}) presentó una excelente correlación en la mayoría de las regiones, lo que sugiere una robustez general en

la estimación de esta variable. Sin embargo, la temperatura máxima (T_{max}) fue aceptable en la región de Valparaíso, mostrando imprecisión en los análisis, mientras que en otras regiones los resultados fueron excelentes. Las dificultades en la estimación de T_{min} y T_{max} en Valparaíso podrían estar relacionadas con características climáticas y geográficas locales.

Las fluctuaciones de temperatura y precipitación en Valparaíso están fuertemente influenciadas por la elevación y la ubicación geográfica en relación con las principales cadenas montañosas, como la cordillera de la Costa y la cordillera de los Andes. En estas áreas, las temperaturas tienden a disminuir con la elevación, y la oscilación térmica está controlada en gran medida por la proximidad al mar (Luebert y Pliscoff, 2012). Este comportamiento es consistente con estudios previos, como el de Berndt y Haberlandt (2018) en Alemania, quienes encontraron que la inclusión de variables secundarias como la elevación mejora significativamente la precisión de la interpolación, logrando hasta un 70 % de mejora en la estimación de la temperatura media anual.

Qian *et al.* (2021) analizaron diferentes técnicas de interpolación para la temperatura del aire en China, descubriendo que los modelos de Ponderación por Distancia Inversa (IDW) y Kriging Ordinario (OK) mostraban un bajo desempeño según la evaluación con RMSE. En cambio, los modelos de Regresión por Proceso Gaussiano (GPR) fueron más confiables, especialmente cuando se integraba la elevación como variable secundaria, mejorando la precisión, especialmente durante los meses de verano. Estos hallazgos subrayan la importancia de considerar la elevación en regiones montañosas y costeras como Valparaíso, donde la topografía juega un papel crucial en la variabilidad climática.

El modelo subestimó la humedad relativa mínima (HR_{min}) en varias regiones, pero fue preciso en las regiones de Maule, Ñuble, Biobío y La Araucanía. Por otro lado, la humedad relativa máxima (HR_{max}) tendió a ser sobreestimada en valores bajos en el análisis cualitativo. Esta variabilidad en la precisión podría reflejar la complejidad de estimar la humedad relativa en diferentes contextos geográficos, aunque el modelo demostró ser confiable para las regiones evaluadas. La humedad

relativa media (HRmed), en cambio, mostró una excelente precisión en todas las regiones, evidenciando una capacidad consistente para estimar esta variable.

Recientemente, Rosillon *et al.* (2024) evaluaron en Bélgica distintos algoritmos de interpolación para variables de temperatura y humedad relativa en tiempo real, incluyendo Vecino Más Cercano (NN), Ponderación de Distancia Inversa (IDW), Regresión Lineal Múltiple (mullR), Kriging Ordinario (OK) y Kriging con Deriva Externa (KED). Concluyeron que el modelo KED basado en la elevación como derivada externa fue el más confiable y preciso en ciertas ubicaciones.

La evapotranspiración de referencia (ET_o) y la acumulada semanal (ET_o 7) mostraron una excelente correlación en todas las regiones en el análisis cualitativo, subrayando la confiabilidad del modelo para estimar esta variable. Dado que la ET_o cuantifica la demanda evaporativa del aire, es crucial para calcular las necesidades hídricas de los cultivos (Gavilán, 2018). Por lo tanto, este modelo podría ser una herramienta relevante para generar predicciones agrícolas en Chile y ser clave en la gestión hídrica y la planificación agrícola, donde una estimación precisa puede ayudar a optimizar el uso del agua en función de las necesidades reales de los cultivos.

Por otro lado, la precipitación acumulada (P_p) mostró una precisión inaceptable en todas las regiones, con especial dificultad en Valparaíso. Esto podría estar relacionado con la alta variabilidad espacial y temporal de las precipitaciones en la zona central y sur de Chile. La variabilidad de los patrones de precipitación, como lo indica el reporte anual de la evolución del clima en Chile, donde se observan tendencias negativas en la precipitación desde la zona norte hasta el Biobío, y positivas al sur de La Araucanía (Villarroel, 2022), sugiere una difícil estimación de esta variable.

Estudios previos, como el de Thornton *et al.* (1997) en Turquía, utilizaron el modelo Spline Completamente Regularizado (CRS) para interpolar la precipitación en ausencia de un Modelo de Elevación Digital (DEM), mostrando buenos resultados en función de los valores de RMSE (Apaydin *et al.*, 2004). Sin embargo, este éxito estuvo respaldado por una alta densidad de estaciones meteorológicas y pluviómetros. En una región turca se emplearon 85 estaciones meteorológicas,

mientras que en este estudio la disponibilidad de estaciones meteorológicas oscilaba entre 4 y 5 según la región, lo que resalta la necesidad de una mayor implementación de estaciones meteorológicas en el territorio nacional.

En Chile, hay una estación de medición de precipitaciones por cada 818 km² y una estación de medición de temperatura por cada 1.364 km² (CCCC, 2019), lo que dificulta la estimación precisa de datos climáticos. Según Hubbard (1994), para capturar adecuadamente la variabilidad climática, las estaciones de temperatura deberían ubicarse cada 60 km y las de precipitación cada 5 km en terrenos planos. Esta densidad es mucho mayor que la actual en Chile. Como se muestra en la Tabla 2, las distancias entre las estaciones meteorológicas utilizadas en este estudio y la estación de referencia varían entre 12,89 y 66,89 km. Para la variable de precipitación, estas distancias están lejos de ser óptimas en terrenos planos, sin considerar la elevación. Además, la mayoría de los datos generados por las estaciones meteorológicas de precipitación a menudo presentan diferencias extremas, presumiblemente debido a la falta de mantenimiento o mal funcionamiento (Fuentes, 2022). Los errores en los registros de datos también pueden derivarse de una mala ubicación de las estaciones, donde la proximidad a árboles o edificios puede afectar la calidad de los datos (Mesenguer-Ruiz y Sarricolea, 2017). Es fundamental disponer de datos de calidad que reflejen la variabilidad propia de la dinámica climática y no errores derivados de malas prácticas (Venema *et al.*, 2012).

La radiación solar (R_s) y la velocidad del viento (u_2) también mostraron variabilidad en su precisión, con resultados menos precisos en Valparaíso y La Araucanía. Estos resultados indican la necesidad de ajustar el modelo para mejorar la estimación de estas variables. Como se ha mencionado anteriormente, la integración de la elevación como una variable adicional podría ser una estrategia efectiva para mejorar la interpolación en estas zonas, principalmente en la velocidad del viento que es particularmente sensible a los factores locales, como la orografía y rugosidad del terreno (Whitemann, 2000).

Las limitaciones observadas en la región de Valparaíso subrayan la necesidad de ajustes adicionales para mejorar la precisión. La consideración de estas

limitaciones en futuros desarrollos del modelo permitirá una mejor adaptación a las características locales, reduciendo los errores de interpolación y mejorando la utilidad de las estimaciones climáticas en estas áreas críticas.

A pesar de las variaciones en la precisión de la interpolación entre las diferentes variables climáticas, el modelo de interpolación implementado demostró una notable confiabilidad, especialmente en las regiones centrales de Chile, como la Metropolitana, O'Higgins, Maule y Biobío. Estas regiones se beneficiaron particularmente del modelo, mostrando una excelente correlación y precisión en la mayoría de las variables evaluadas, incluyendo la temperatura media (T_{med}), temperatura máxima (T_{max}), humedad relativa media (HR_{med}), y la evapotranspiración de referencia (ET_o) y acumulada semanal (ET_o7).

CONCLUSIONES

1. El modelo de interpolación mostró variaciones significativas en la precisión de la estimación de las variables climáticas analizadas.
2. La temperatura media (T_{med}), humedad relativa media (HR_{med}), evapotranspiración de referencia (ET_o) y evapotranspiración de referencia semanal (ET_o7) fueron estimadas con alta precisión para las regiones según los análisis cuantitativo y cualitativo.
3. El modelo de interpolación demostró alta confiabilidad en las regiones centrales de Chile para todas las variables, en excepción la precipitación acumulada (P_p).
4. La temperatura mínima (T_{min}), velocidad del viento (u_2) y precipitación acumulada (P_p) presentaron problemas de estimación, especialmente en la región de Valparaíso y Araucanía.
5. Las limitaciones identificadas en el modelo propuesto destacan la necesidad de realizar ajustes adicionales, como la elevación, podría ser una estrategia para mejorar la estimación en ciertas variables climáticas, especialmente para la región de Valparaíso.
6. La baja densidad de estaciones meteorológicas en Chile representa una limitación significativa para la precisión de interpolaciones climáticas.

7. El modelo de interpolación posee una alta confiabilidad en la estimación de variables clave para la agricultura como la evapotranspiración de referencia, siendo una herramienta valiosa para generar estimaciones en zonas con inexistencia de estos datos.

REFERENCIAS

1. Antúñez, M., L. Gervasoni, E. Maggiori y A. Thomas. 2013. Desarrollo de una herramienta para automatizar la estimación de datos faltantes en informes meteorológicos. 16º Concurso de Trabajos Estudiantiles (EST) - JAIIO 42 (2013). 16 – 20 septiembre, 2013. Centro Latinoamericano de Estudios en Informática. Córdoba, Argentina.
2. Apaydin, H., F. K. Sonmez and Y. E. Yildirim. 2004. Spatial interpolation techniques for climate data in the GAP region in Turkey. *Climat. Res.* 28(1): 31-40.
3. Berndt, C., and U. Haberlandt. 2018. Spatial interpolation of climate variables in Northern Germany—Influence of temporal resolution and network density. *Journal of Hydrology: Regional Studies.* 15: 184-202.
4. Casas, R. 2012. El suelo de cultivo y las condiciones climáticas. Paraninfo. España.
5. CCCC. 2019. Recursos hídricos en Chile: Impactos y adaptación al cambio climático. Comité Científico de Cambio Climático - Mesa Agua. Santiago, Chile.
6. Chang, K.T. 2006. Introduction to geographic information systems (3a.ed.). McGraw-Hill. Nueva York, Estados Unidos.
7. Fuentes, G. S. 2022. Desarrollo de un método para estimar la distribución espacial de la precipitación mensual en alta resolución en el desierto de Atacama (Chile) a partir de productos chirps. Tesis, Magíster en Gestión Territorial de Recursos Naturales. Universidad de Chile, Facultad de Ciencias Agronómicas. Santiago, Chile.
8. Garreaud, R. D., C. Alvarez-Garreton, J. Barichivich, J. P. Boisier, D. Christie, Galleguillos and M. Zambrano-Bigiarini. 2017. The 2010–2015 megadrought in central Chile: impacts on regional hydroclimate and vegetation. *Hydr. Syst. Sci.* 21(12): 6307-6327.

9. Gavilán, P. 2018. Evapotranspiración de referencia estandarizada en el sur de España. AGRICULTURA. Madrid, España.
10. Hubbard, K.G., 1994. Spatial variability of daily weather variables in the high plains of the USA. *Agric. For. Meteorol.*, 68: 29-41.
11. INIA. 2024. Red Agrometeorológica [en línea]. Instituto de Investigaciones Agropecuarias (INIA), Chile. <<https://agrometeorologia.cl>>. [Consulta: 12 junio 2024].
12. Jamieson, P. D., J. R. Porter and D. R. Wilson. 1991. A test of the computer simulation model ARCWHEAT1 on wheat crops grown in New Zealand. *Field Crops Res.* 27(4): 337-350.
13. Luebert, F., y P. Pliscoff. 2012. Variabilidad climática y bioclimas de la Región de Valparaíso, Chile. *Investig. Geogr.* 44: 41-56.
14. Meseguer-Ruiz, O., y P. Sarricolea. 2017. Detección de inhomogeneidades en series de precipitación diaria en la región centro-sur de Chile. *Interciencia.* 42(4): 242-249.
15. ODEPA. 2022. Agua para la agricultura [en línea]. Oficina de Estudios y Políticas Agrarias, Chile. <https://www.odepa.gob.cl/sustentabilidad/agricultura-sustentable/agua>. [Consulta: 20 julio 2024].
16. Pereira, L. S., I. Cordery and I. Iacovides. 2009. *Coping with water scarcity: Addressing the challenges*. Springer. Nueva York, Estados Unidos.
17. Qian, H., M. Wang, K. Liu, K. Li and Z. Jiang. 2022. GPRChinaTemp1km: a high-resolution monthly air temperature data set for China (1951–2020) based on machine learning. *Earth Sys. Sci. Dat.* 14(7): 3273-3292.
18. Rosillon, D. J., A. Jago, J. P. Huart, P. Bogaert, M. Journée, S. Dandrifosse and V. Planchon. 2024. Near real-time spatial interpolation of hourly air temperature and humidity for agricultural decision support systems. *Comput. Elect. Agri.* 223: 109093.
19. Sepúlveda, J. 2020. Importancia de las estaciones meteorológicas para la toma de decisiones en la agricultura. Documento de Trabajo. Centro de Investigación en Agricultura y Biotecnología, Universidad Nacional Abierta y a Distancia. Florida, Estados Unidos.

20. Silva, D., F. J. Meza and E. Varas. 2010. Estimating reference evapotranspiration (ET_o) using numerical weather forecast data in central Chile. *Jour. Hydr.* 382(1-4): 64-71.
21. Thornton, P. E., S. W. Running and M. A. White. 1997. Generating surfaces of daily meteorological variables over large regions of complex terrain. *J Hydrol* 190:214–251.
22. Vicuna, S. and J.A. Dracup. 2007. The evolution of climate change impact studies on hydrology and water resources in California. *Climatic Change*. 82(3): 327-350.
23. Villarroel, C., Vásquez, R., Aravena, C., y Vilches, C. 2022. Reporte Anual de la evolución del clima en Chile 2021. Informe Técnico N°6. Dirección Meteorológica de Chile. Santiago, Chile.
24. Ward, A. D and S. W. Trimble. 2004. *Environmental Hydrology*. CRC Press. Florida, Estados Unidos.
25. Whiteman, C. D. 2000. *Mountain meteorology: fundamentals and applications*. Oxford University Press. Inglaterra, Reino Unido.