



UNIVERSIDAD BERNARDO O'HIGGINS
FACULTAD DE INGENIERÍA CIENCIA Y TECNOLOGÍA
ESCUELA DE INGENIERÍA INFORMÁTICA

**PREDICCIÓN DE HELADAS UTILIZANDO TÉCNICAS DE
APRENDIZAJE AUTOMÁTICO**

Entrega Inicial

EDUARDO JERALDO

Profesor Guía: Broderick Crawford



Santiago, Chile

2024

Índice general

| | |
|--|-----------|
| 1. Introducción | 1 |
| 1.1. Importancia de predicción de heladas | 2 |
| 1.2. Objetivos | 3 |
| 1.3. Metodología enfocada en Ciencia de Datos | 3 |
| 1.4. Estructura de la tesis | 4 |
| 2. Estado del Arte | 7 |
| 2.1. Tecnicas de predicción de temperatura | 7 |
| 2.2. Aplicaciones de aprendizaje automático en predicción de temperatura | 8 |
| 2.3. Trabajos relacionados | 10 |
| 3. Metodología | 11 |
| 3.1. Adquisición y descripción del conjunto de datos | 11 |
| 3.2. Ingeniería de características | 12 |
| 3.2.1. Manejo de datos faltantes | 12 |
| 3.2.2. Transformación de variables | 12 |
| 3.2.3. Análisis de periodicidad | 12 |
| 3.3. División del conjunto de datos | 12 |
| 3.4. Modelos para evaluación | 13 |
| 3.4.1. Modelos Base | 13 |
| 3.4.2. Modelos de Aprendizaje Automático | 13 |
| 3.5. Evaluación y selección de modelos | 14 |
| 4. Bibliografía | 15 |



Glosario

CNN Convolutional Neural Network

LSTM Long-Short Term Memory

Resumen

La predicción precisa de la temperatura es fundamental para diversos sectores, como la agricultura, la gestión energética y la planificación urbana. Los enfoques tradicionales basados en modelos estadísticos han demostrado limitaciones para capturar la complejidad de los patrones climáticos. Además, los métodos convencionales a menudo no aprovechan la riqueza de los datos históricos disponibles. En este estudio, proponemos una solución basada en técnicas de aprendizaje automático para abordar las deficiencias de los enfoques anteriores.

Nuestra investigación se centra en el desarrollo de modelos de aprendizaje automático avanzados, capaces de procesar y aprender de grandes conjuntos de datos climáticos históricos. Utilizando un conjunto de datos que abarca tres años de registros de temperatura, humedad, velocidad del viento y precipitación, hemos implementado y evaluado una variedad de modelos, incluyendo redes neuronales densas, redes neuronales convolucionales (CNN), redes neuronales recurrentes de largo y corto plazo (LSTM), y modelos híbridos que combinan estas arquitecturas.

Los resultados preliminares muestran que nuestros modelos de aprendizaje automático superan significativamente los enfoques tradicionales en términos de precisión de predicción. En particular, el modelo híbrido CNN-LSTM alcanzó un error medio absoluto de sólo 0.26°C en el conjunto de prueba, lo que demuestra su capacidad para capturar patrones complejos en los datos climáticos.

Esta solución basada en aprendizaje automático tiene implicaciones significativas para la toma de decisiones informada en diversos sectores. Al proporcionar predicciones de temperatura más precisas, nuestro enfoque puede contribuir a mejorar la eficiencia energética, optimizar las prácticas agrícolas y apoyar una mejor planificación urbana y gestión de recursos. Además, nuestro trabajo sienta las bases para futuras investigaciones en el campo de la predicción climática impulsada por datos.

Introducción

Las heladas, definidas como temperaturas bajo los 0 °C (Fuentes et al., 2018), representan una de las principales amenazas climáticas para diversas actividades económicas, especialmente en el sector agrícola. La capacidad de predecir con precisión la ocurrencia de heladas y su duración temporal es de vital importancia para la toma de decisiones informadas y la implementación oportuna de medidas preventivas [referencia sobre importancia de pronósticos de heladas]. Estas medidas pueden ayudar a reducir significativamente los daños en los cultivos, las pérdidas de calidad y los costos asociados a las heladas [referencia sobre impactos económicos de heladas].

Las heladas pueden clasificarse principalmente en dos tipos: radiativas y advectivas [referencia sobre tipos de heladas]. Las heladas radiativas ocurren típicamente durante la noche y son causadas por la intensa pérdida de radiación de onda larga desde la superficie terrestre hacia la atmósfera, lo que enfría el aire cercano al suelo y provoca la congelación del agua en las hojas de las plantas [referencia sobre formación de heladas radiativas]. Este tipo de heladas se caracterizan por condiciones de viento en calma, inversión térmica, baja humedad, punto de rocío bajo y ausencia de nubes [referencia sobre condiciones de heladas radiativas]. Por otro lado, las heladas advectivas se desarrollan debido a la incursión de masas de aire frío y seco, generalmente asociadas con frentes polares [referencia sobre formación de heladas advectivas]. Estas heladas pueden ocurrir tanto de día como de noche y suelen ser más perjudiciales para los cultivos debido a su mayor duración e intensidad [referencia sobre impactos de heladas advectivas].

Ante esta situación, el desarrollo de sistemas de predicción de heladas y su duración basados en técnicas de aprendizaje automático (machine learning) surge como una solución prometedora [referencia sobre uso de machine learning para pronósticos]. Estos sistemas tienen el potencial de brindar alertas tempranas y estimar con precisión la ventana de tiempo durante la cual se mantendrán las condiciones de helada, permitiendo a los agricultores tomar las medidas necesarias para mitigar los impactos negativos en sus cultivos [referencia sobre beneficios de sistemas de alerta temprana].

Este proyecto propone el desarrollo de un sistema de predicción de heladas basado en redes neuronales artificiales, utilizando datos históricos de variables meteorológicas como temperatura, humedad relativa, radiación, precipitación y viento [referencia sobre variables relevantes para predicción de heladas]. El objetivo principal es brindar una alerta temprana de al menos 6 horas de anticipación y estimar la duración de las condiciones de helada,

con el fin de ayudar a los agricultores a implementar estrategias efectivas para proteger sus cultivos y minimizar las pérdidas económicas. Para evaluar la calidad de los pronósticos probabilísticos de heladas, se requiere el uso de reglas de puntuación adecuadas que asignen puntajes numéricos basados en la distribución predictiva y el evento o valor que se materializa, incentivando al pronosticador a realizar evaluaciones cuidadosas y honestas (Gneiting and Raftery, 2007).

1.1. Importancia de predicción de heladas

Las heladas son un fenómeno meteorológico que ocurre cuando la temperatura del aire desciende por debajo del punto de congelación del agua (0°C o 32°F). Estas bajas temperaturas pueden tener un impacto significativo en diversos sectores, como la agricultura, la infraestructura y la salud pública.

En el sector agrícola, las heladas representan una amenaza potencial para los cultivos, especialmente durante las etapas de floración y fructificación. Las bajas temperaturas pueden dañar o destruir las plantas, lo que conduce a pérdidas de rendimiento y, en casos extremos, a la pérdida completa de la cosecha. Esto puede tener consecuencias económicas devastadoras para los productores y afectar la seguridad alimentaria de una región.

Además, las heladas pueden causar daños a la infraestructura, como tuberías de agua congeladas, carreteras y puentes dañados, y problemas en los sistemas de transporte y comunicaciones. Estos daños pueden resultar en interrupciones de servicios y costos de reparación considerables.

En cuanto a la salud pública, las heladas prolongadas y severas pueden aumentar el riesgo de enfermedades respiratorias, hipotermia y otros problemas de salud, especialmente para las poblaciones vulnerables, como los ancianos y las personas sin hogar.

Debido a estos impactos significativos, la predicción precisa de las heladas es crucial para la toma de decisiones informadas y la implementación de estrategias de mitigación efectivas. Al anticipar con precisión la ocurrencia de heladas, los agricultores pueden tomar medidas preventivas, como la instalación de sistemas de riego por aspersión o la aplicación de coberturas protectoras, para minimizar los daños a los cultivos.

Además, las autoridades locales y los organismos gubernamentales pueden utilizar las predicciones de heladas para planificar y coordinar esfuerzos de preparación, como el mantenimiento de carreteras y la activación de albergues de emergencia para las personas sin hogar.

En resumen, la predicción de heladas desempeña un papel fundamental en la protección de la agricultura, la infraestructura y la salud pública. Al comprender y anticipar

con precisión este fenómeno meteorológico, se pueden tomar medidas proactivas para mitigar sus impactos negativos y garantizar la resiliencia de las comunidades y los sistemas económicos.

1.2. Objetivos

Desarrollar un sistema de predicción de heladas preciso y confiable utilizando técnicas de aprendizaje automático y aprovechando la riqueza de los datos climáticos históricos disponibles.

Los objetivos específicos son los siguientes:

- Recopilar y procesar un conjunto de datos climáticos históricos relevantes para la región de estudio, que incluya variables como temperatura, humedad, velocidad del viento y precipitación.
- Aplicar técnicas de ingeniería de características y preprocesamiento de datos para garantizar la calidad y consistencia de los conjuntos de entrenamiento, validación y prueba.
- Implementar y evaluar una variedad de modelos de aprendizaje automático, incluyendo redes neuronales densas, redes neuronales convolucionales (CNN), redes neuronales recurrentes de largo y corto plazo (LSTM), y modelos híbridos que combinen estas arquitecturas.
- Comparar el rendimiento de los diferentes modelos en términos de precisión de predicción de heladas, utilizando métricas adecuadas como el error medio absoluto.
- Seleccionar el modelo óptimo y realizar un ajuste fino de sus hiperparámetros para maximizar su capacidad predictiva y minimizar el error.

Al lograr estos objetivos, se espera que este proyecto contribuya a mejorar la capacidad de pronóstico de heladas y a proteger los cultivos, la infraestructura y la salud pública de los impactos negativos de este fenómeno meteorológico.

1.3. Metodología enfocada en Ciencia de Datos

[+]

En este proyecto, se ha adoptado un enfoque basado en la ciencia de datos para abordar el desafío de la predicción de heladas utilizando técnicas de aprendizaje automático. La metodología empleada sigue un flujo de trabajo iterativo que consta de varias etapas clave:

- **Adquisición y preparación de datos**

Esta etapa involucra la recopilación de datos climáticos históricos relevantes para la región de estudio. Se han obtenido registros de variables como temperatura, humedad, velocidad del viento y precipitación a lo largo de varios años. Posteriormente, se ha aplicado un riguroso proceso de ingeniería de características y preprocesamiento de datos para garantizar la calidad y consistencia de los conjuntos de entrenamiento, validación y prueba.

- **Exploración y análisis de datos**

Antes de la construcción de los modelos, se ha realizado una exploración exhaustiva de los datos para comprender sus características, patrones y relaciones. Esto ha incluido el análisis de la distribución de variables, la identificación de valores atípicos, el manejo de datos faltantes y el estudio de la periodicidad y tendencias temporales.

- **Desarrollo y evaluación de modelos**

En esta etapa, se han implementado y evaluado diversos modelos de aprendizaje automático, incluyendo redes neuronales densas, redes neuronales convolucionales (CNN), redes neuronales recurrentes de largo y corto plazo (LSTM), y modelos híbridos que combinan estas arquitecturas. Cada modelo ha sido entrenado utilizando los conjuntos de datos preparados y su rendimiento ha sido evaluado mediante métricas de precisión como el error medio absoluto.

- **Selección e implementación del modelo óptimo**

Después de la evaluación exhaustiva de los diferentes modelos, se ha seleccionado el modelo que ha demostrado el mejor rendimiento en la predicción de heladas. Este modelo óptimo ha sido objeto de un ajuste fino de hiperparámetros para maximizar su capacidad predictiva y minimizar el error.

Este enfoque metodológico basado en la ciencia de datos ha permitido abordar el problema de la predicción de heladas de manera sistemática y rigurosa, aprovechando al máximo la potencia de las técnicas de aprendizaje automático y el análisis de datos para obtener resultados precisos y confiables.

1.4. Estructura de la tesis

Esta tesis se organiza de la siguiente manera:

- **Capítulo 1: Introducción.**

Se presenta el contexto y la importancia de la predicción de heladas, se describen los objetivos del estudio y se presenta la estructura de la tesis.

- **Capítulo 2:** Estado del arte.

Este capítulo proporciona una revisión exhaustiva de la literatura relevante en el campo de la predicción de heladas y el aprendizaje automático aplicado a fenómenos meteorológicos. Se analizan los enfoques tradicionales utilizados para la predicción de heladas, así como las técnicas de aprendizaje automático que han sido empleadas en estudios previos. Se identifican las fortalezas y limitaciones de los métodos existentes, lo que justifica la necesidad de explorar nuevos enfoques.

- **Capítulo 3:** Metodología.

En este capítulo, se describe detalladamente la metodología utilizada en el proyecto. Se explica el proceso de recopilación y procesamiento de datos climáticos históricos, incluyendo la ingeniería de características y el preprocesamiento de datos. Además, se presentan los diferentes modelos de aprendizaje automático implementados, como redes neuronales densas, redes neuronales convolucionales (CNN), redes neuronales recurrentes de largo y corto plazo (LSTM), y modelos híbridos que combinan estas arquitecturas. Se detallan los criterios de evaluación y comparación utilizados para seleccionar el modelo óptimo.

- **Capítulo 4:** Resultados y análisis.

En este capítulo, se presentan los resultados obtenidos de la implementación y evaluación de los diferentes modelos de aprendizaje automático. Se comparan los rendimientos de los modelos en términos de precisión de predicción de heladas, utilizando métricas como el error medio absoluto. Se analiza en profundidad el modelo seleccionado como óptimo y se discuten sus fortalezas y limitaciones.

- **Capítulo 5:** Conclusiones y trabajo futuro.

Este capítulo final resume las conclusiones principales del proyecto y destaca los logros alcanzados en la predicción de heladas utilizando técnicas de aprendizaje automático. Se discuten las implicaciones prácticas de los resultados y su potencial impacto en diversos sectores. Además, se identifican las limitaciones del estudio y se sugieren direcciones para trabajos futuros y mejoras potenciales.

- **Referencias bibliográficas**

Esta sección incluye una lista de las fuentes bibliográficas citadas a lo largo de la tesis.

- **Anexos**

Los apéndices incluyen información complementaria relevante, como detalles de implementación, código fuente y otros materiales de apoyo.

A lo largo de la tesis, se presentan tablas, gráficos y figuras que ilustran los resultados y facilitan la comprensión de los conceptos y métodos utilizados. Además, se incluyen

referencias bibliográficas para respaldar las afirmaciones y argumentos presentados en cada capítulo.

En resumen, esta tesis aborda un problema importante y actual en el campo de la meteorología y la agricultura, utilizando técnicas de aprendizaje automático para mejorar la predicción de heladas y proteger los cultivos de los impactos negativos de este fenómeno meteorológico.

Estado del Arte



*debe considerar
varias referencias
bibliográficas...*

La predicción precisa de la temperatura es fundamental para diversos sectores, como la agricultura, la gestión energética y la planificación urbana. Los enfoques tradicionales basados en modelos estadísticos han demostrado limitaciones para capturar la complejidad de los patrones climáticos. Además, los métodos convencionales a menudo no aprovechan la riqueza de los datos históricos disponibles. En este estudio, proponemos una solución basada en técnicas de aprendizaje automático para abordar las deficiencias de los enfoques anteriores.

Nuestra investigación se centra en el desarrollo de modelos de aprendizaje automático avanzados, capaces de procesar y aprender de grandes conjuntos de datos climáticos históricos. Utilizando un conjunto de datos que abarca tres años de registros de temperatura, humedad, velocidad del viento y precipitación, hemos implementado y evaluado una variedad de modelos, incluyendo redes neuronales densas, redes neuronales convolucionales (CNN), redes neuronales recurrentes de largo y corto plazo (LSTM), y modelos híbridos que combinan estas arquitecturas.

Los resultados preliminares muestran que nuestros modelos de aprendizaje automático superan significativamente los enfoques tradicionales en términos de precisión de predicción. En particular, el modelo híbrido CNN-LSTM alcanzó un error medio absoluto de sólo 0.26°C en el conjunto de prueba, lo que demuestra su capacidad para capturar patrones complejos en los datos climáticos.

2.1. Técnicas de predicción de temperatura

La predicción precisa de la temperatura es un desafío fundamental en diversas áreas, como la meteorología, la agricultura, la gestión energética y la planificación urbana. A lo largo de los años, se han desarrollado y aplicado varias técnicas para abordar este problema. A continuación, se presentan algunas de las principales técnicas utilizadas en la predicción de temperatura:

Modelos estadísticos: Los modelos estadísticos han sido ampliamente utilizados en la predicción de temperatura. Estos modelos se basan en el análisis de datos históricos y la identificación de patrones y tendencias. Algunas de las técnicas estadísticas comúnmente empleadas incluyen:

Modelos de regresión lineal y no lineal: Estos modelos establecen una relación

matemática entre la temperatura y otras variables predictoras, como la humedad, la radiación solar y la velocidad del viento. Modelos de series temporales: Técnicas como el análisis de series temporales ARIMA (Autoregressive Integrated Moving Average) y los modelos SARIMA (Seasonal ARIMA) se utilizan para modelar y predecir series de datos de temperatura que exhiben patrones estacionales y tendencias. Modelos numéricos de predicción meteorológica: Los modelos numéricos de predicción meteorológica (NWP, por sus siglas en inglés) se basan en ecuaciones matemáticas que describen los procesos físicos de la atmósfera. Estos modelos utilizan datos observados como condiciones iniciales y simulan la evolución futura de variables meteorológicas, incluyendo la temperatura. Algunos ejemplos de modelos NWP ampliamente utilizados son el Modelo Global de Predicción Ambiental (GFS) y el Modelo Europeo de Predicción a Plazo Medio (ECMWF).

Técnicas de teledetección: Las técnicas de teledetección, como la utilización de imágenes satelitales y datos de sensores remotos, se han empleado para estimar la temperatura de la superficie terrestre y los patrones de temperatura atmosférica. Estas técnicas se basan en la medición de la radiación electromagnética emitida o reflejada por la superficie de la Tierra y la atmósfera.

Redes neuronales artificiales: En los últimos años, las redes neuronales artificiales (ANN) han ganado popularidad en la predicción de temperatura debido a su capacidad para modelar relaciones complejas y no lineales entre las variables de entrada y la temperatura objetivo. Estas redes pueden aprender patrones a partir de datos históricos y realizar predicciones precisas.

Técnicas de aprendizaje automático: Además de las redes neuronales, otras técnicas de aprendizaje automático, como las máquinas de vectores de soporte (SVM), los árboles de decisión y los modelos de conjunto (ensemble), han sido exploradas para la predicción de temperatura. Estas técnicas pueden manejar datos de alta dimensionalidad y capturar patrones complejos en los datos.

2.2. Aplicaciones de aprendizaje automático en predicción de temperatura

En los últimos años, las técnicas de aprendizaje automático (machine learning) han ganado una creciente popularidad en el ámbito de la predicción de temperatura debido a su capacidad para modelar relaciones complejas y no lineales presentes en los datos climáticos. A continuación, se presentan algunas de las principales aplicaciones del aprendizaje automático en este campo:

- **Agricultura y gestión de cultivos:**

La predicción precisa de la temperatura es crucial en la agricultura para optimizar las prácticas de cultivo, planificar la siembra y la cosecha, y minimizar los riesgos asociados con las condiciones climáticas adversas. Los modelos de aprendizaje automático han demostrado su eficacia en la predicción de temperaturas a corto y mediano plazo, lo que permite a los agricultores tomar decisiones informadas sobre el riego, la aplicación de fertilizantes y la protección de cultivos.

- **Gestión energética:**

La demanda de energía, tanto para calefacción como para refrigeración, está estrechamente relacionada con las condiciones climáticas, especialmente la temperatura. Las empresas de servicios públicos y los proveedores de energía utilizan modelos de aprendizaje automático para predecir la temperatura y ajustar la producción y distribución de energía de manera eficiente, reduciendo así los costos operativos y minimizando el impacto ambiental.

- **Planificación urbana y construcción:**

Las predicciones de temperatura son fundamentales en la planificación urbana y el diseño de edificios. Los modelos de aprendizaje automático se utilizan para estimar las cargas de calefacción y refrigeración, optimizar la eficiencia energética de los edificios y planificar la infraestructura urbana, como sistemas de aire acondicionado y redes de calefacción urbana.

- **Monitoreo y alerta de eventos extremos:**

Los eventos climáticos extremos, como las olas de calor o las heladas, pueden tener impactos significativos en la salud pública, la agricultura y la infraestructura. Los modelos de aprendizaje automático se han aplicado para predecir la ocurrencia de estos eventos y generar alertas tempranas, permitiendo a las autoridades y a las comunidades prepararse adecuadamente y mitigar los impactos potenciales.

- **Investigación climática:**

En el campo de la investigación climática, los modelos de aprendizaje automático se utilizan para analizar y comprender los patrones de temperatura a largo plazo, identificar tendencias y estudiar los efectos del cambio climático. Estos modelos pueden procesar grandes volúmenes de datos climáticos históricos y revelar insights valiosos para la toma de decisiones y la formulación de políticas relacionadas con el clima.

Estas aplicaciones destacan la importancia del aprendizaje automático en la predicción de temperatura y su impacto en diversos sectores. A medida que las técnicas de aprendizaje automático continúan evolucionando y se dispone de más datos climáticos, se espera que

estas aplicaciones se vuelvan aún más precisas y eficientes, brindando información valiosa para abordar los desafíos relacionados con el clima y la sostenibilidad.

2.3. Trabajos relacionados

Metodología [+]

En este capítulo, se detalla la metodología empleada en el desarrollo del sistema de predicción de heladas utilizando técnicas de aprendizaje automático. Se describen los pasos seguidos, desde la adquisición y preparación de los datos hasta la implementación y evaluación de los modelos.

3.1. Adquisición y descripción del conjunto de datos

El primer paso en el proceso fue la obtención de un conjunto de datos climáticos históricos relevantes para la región de estudio. Estos datos fueron recopilados a través de una consulta realizada a la API [falta incluir], extrayendo información meteorológica específica de la ubicación ... [falta agregar].

El conjunto de datos obtenido contiene diversas variables climáticas, incluyendo:

- Fechas y horas de los registros
- Temperatura promedio
- Humedad relativa promedio
- Velocidad promedio del viento
- Dirección promedio del viento
- Ráfaga máxima promedio del viento
- Tasa de precipitación promedio
- Acumulación de precipitación promedio

Estas variables fueron seleccionadas debido a su relevancia e impacto potencial en la predicción de heladas, ya que factores como la temperatura, la humedad, el viento y la precipitación pueden influir en la formación y la intensidad de este fenómeno meteorológico.

3.2. Ingeniería de características

Antes de proceder con el entrenamiento de los modelos, se realizó un exhaustivo proceso de ingeniería de características y preprocesamiento de datos para garantizar la calidad y consistencia de los conjuntos de entrenamiento, validación y prueba.

3.2.1. Manejo de datos faltantes

Se identificaron columnas que contenían un alto número de datos nulos y se decidió descartarlas del conjunto de datos, ya que la falta de información en esas columnas podría afectar negativamente el rendimiento de los modelos. Además, se eliminaron los días completos que contenían valores faltantes para mantener la integridad de los datos.

3.2.2. Transformación de variables

Se agregó una nueva columna llamada "dew_point" (punto de rocío), calculada a partir de la temperatura promedio y la humedad relativa promedio utilizando la fórmula: ... El punto de rocío es una medida importante que indica la temperatura a la cual el aire se satura y se forma rocío, lo que influye en la sensación térmica y las condiciones climáticas.

3.2.3. Análisis de periodicidad

Además, se realizó un análisis de la periodicidad del conjunto de datos utilizando la transformada de Fourier, que reveló una tendencia a tener una periodicidad diaria en los datos. Para aprovechar esta información, se convirtieron las fechas y horas en componentes seno y coseno, lo que permitió capturar la información temporal de manera más efectiva.

3.3. División del conjunto de datos

El conjunto de datos se dividió en tres subconjuntos: entrenamiento, validación y prueba, siguiendo una proporción aproximada de 70:20:10, respectivamente. Esto aseguró que el modelo se entrenara en la mayoría de los datos y se evaluara en conjuntos separados para obtener una estimación realista de su rendimiento.

Finalmente, se aplicó la técnica MinMaxScaler exclusivamente al conjunto de entrenamiento para normalizar las características numéricas entre un rango de 0 a 1, evitando así la fuga de información entre el conjunto de entrenamiento y los conjuntos de prueba y validación.

3.4. Modelos para evaluación

En esta etapa, se implementaron y evaluaron una variedad de modelos de aprendizaje automático con el objetivo de encontrar el enfoque más efectivo para la predicción de heladas. Se exploraron diferentes arquitecturas, desde modelos lineales hasta redes neuronales profundas, aprovechando la capacidad de estos modelos para capturar patrones complejos en los datos climáticos históricos.

3.4.1. Modelos Base

Como punto de partida, se implementaron modelos de base que sirvieron como línea de referencia para evaluar el rendimiento de los modelos más sofisticados. Estos modelos incluyeron:

- **Modelo de Repetición de Última Temperatura:** Este modelo asume que la temperatura futura será la misma que la última observación registrada.
- **Modelo de Repetición del Último Valor:** Similar al anterior, pero utiliza el último valor observado en el conjunto de datos como predicción.
- Aunque estos modelos son relativamente simples, proporcionaron un punto de referencia inicial para comparar la precisión de los modelos más complejos.

3.4.2. Modelos de Aprendizaje Automático

Se implementaron varios modelos basados en redes neuronales artificiales (ANN), aprovechando su capacidad para modelar relaciones no lineales y capturar patrones complejos en los datos. Los modelos implementados incluyeron: [cambiar todos estos a sus propias secciones, entre una y dos páginas cada uno]

- **Modelo Lineal de una Capa Densa:** Este modelo utiliza una sola capa densa para aprender relaciones lineales entre las características de entrada y la variable objetivo (temperatura).
- **Modelo Densa de Tres Capas:** Este modelo consta de tres capas densas, con dos capas intermedias de 64 neuronas cada una y una capa de salida. Esta arquitectura más profunda permite aprender representaciones más complejas de los datos.
- **Modelo LSTM Simple:** Utilizando una capa LSTM (Long Short-Term Memory) con 32 unidades y una capa densa de salida, este modelo es adecuado para el análisis de series temporales y puede capturar dependencias a largo plazo en los datos.

- **Modelo CNN con Capa Densa:** Esta arquitectura combina una capa de convolución 1D con 32 filtros, seguida de una capa densa con 32 neuronas y una capa de salida. La convolución permite identificar patrones locales en los datos antes de ser procesados por las capas densas.
- **Modelo de Combinación CNN y LSTM:** Este modelo combina una capa de convolución 1D con 32 filtros y una capa LSTM con 32 unidades, seguida de una capa densa de salida. Esta combinación permite aprovechar tanto la información local como las dependencias a largo plazo en los datos.
- **Modelo AR_LSTM:** Este modelo utiliza la técnica AutoRegressive Integrated Moving Average (ARIMA) en combinación con una capa LSTM y una capa densa de salida. ARIMA es adecuado para modelar series temporales con componentes estacionales y de tendencia.

Cada uno de estos modelos fue entrenado utilizando los conjuntos de datos preparados y su rendimiento fue evaluado mediante métricas de precisión, como el error medio absoluto (MAE).

3.5. Evaluación y selección de modelos

Una vez entrenados los modelos, se evaluó su rendimiento en los conjuntos de validación y prueba. Se compararon los resultados de los diferentes modelos utilizando métricas como el error medio absoluto (MAE) y la precisión de predicción.

Esta evaluación exhaustiva permitió identificar el modelo que proporcionaba las predicciones más precisas y confiables para la tarea de predicción de heladas. El modelo seleccionado como óptimo fue objeto de un ajuste fino de hiperparámetros para maximizar su capacidad predictiva y minimizar el error.

En el siguiente capítulo, se presentarán y analizarán los resultados obtenidos de la implementación y evaluación de los diferentes modelos, resaltando las fortalezas y limitaciones de cada enfoque, así como las implicaciones prácticas de los hallazgos.