



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

INSTITUTO TECNOLÓGICO DE CIUDAD MADERO
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
POSGRADO EN CIENCIAS DE LA COMPUTACIÓN



"POR MI PATRIA Y POR MI BIEN"

TESIS

El uso de técnicas de aprendizaje Automático en aplicaciones del cambio climático.

Que para obtener el grado de:

MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN

Presenta:

Ing. Oscar Román Bozada Zúñiga

G15071315

1172675

Bajo la dirección de:

Director:

Dr. Juan Javier González Barbosa

202134

Codirector:

Dr. Juan Frausto Solís

Ciudad Madero, Tamaulipas. Junio de 2024

Ciudad Madero, Tamaulipas, **13/mayo/2024**

OFICIO No.: U.063/2024

ASUNTO: Autorización de impresión de tesis

C. OSCAR ROMÁN BOZADA ZÚÑIGA
No. DE CONTROL G15071315
P R E S E N T E

Me es grato comunicarle que después de la revisión realizada por el Jurado designado para su Examen de Grado de Maestría en Ciencias de la Computación, se acordó autorizar la impresión de su tesis titulada:

“EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO EN APLICACIONES DEL CAMBIO CLIMÁTICO”

El Jurado está integrado por los siguientes catedráticos:

PRESIDENTE:	DRA.	GUADALUPE CASTILLA VALDEZ
SECRETARIA:	DR.	NELSON RANGEL VALDEZ
VOCAL:	DR.	JUAN JAVIER GONZÁLEZ BARBOSA
SUPLENTE:	DR.	JUAN FRAUSTO SOLÍS
DIRECTOR DE TESIS:	DR.	JUAN JAVIER GONZÁLEZ BARBOSA
CO-DIRECTOR:	DR.	JUAN FRAUSTO SOLÍS

Es muy satisfactorio para la División de Estudios de Posgrado e Investigación compartir con usted el logro de esta meta. Espero que continúe con éxito su desarrollo profesional y dedique su experiencia e inteligencia en beneficio de México.

ATENTAMENTE

Excelencia en Educación Tecnológica®

“Por mi patria y por mi bien”®



MARCO ANTONIO CORONEL GARCÍA
JEFE DE LA DIVISIÓN DE ESTUDIOS DE
POSGRADO E INVESTIGACIÓN



c.c.p.- Archivo

MACG/MLMR



Av. 1º de Mayo y Sor Juana I. de la Cruz S/N Col. Los Mangos C.P. 89440 Cd. Madero, Tam.
Tel. 01 (833) 357 48 20, ext. 3110, e-mail: depi_cdmadero@tecnm.mx
tecnm.mx | cdmadero.tecnm.mx



**DECLARACIONES DE ORIGINALIDAD, PROPIEDAD
INTELECTUAL, CESION DE DERECHOS Y/O
CONFIDENCIALIDAD**

Por medio de la presente, yo Oscar Román Bozada Zúñiga declaro que la tesis titulada El uso de técnicas de aprendizaje Automático en aplicaciones del cambio climático es un trabajo original e inédito de mi autoría, que no ha sido publicado ni presentado en otro lugar para obtener algún grado académico o reconocimiento.

Cedo los derechos patrimoniales de autor de mi tesis al Tecnológico Nacional de México.

Atentamente



Ing. Oscar Román Bozada Zúñiga

AGRADECIMIENTOS

Agradezco infinitamente a mis padres, por apoyarme siempre en todos los proyectos, a los doctores directores de esta tesis Juan Javier González Barbosa y Juan Frausto Solís por su paciencia y habilidad de brindarme su conocimiento para lograr las metas, a todo el programa de maestría del Instituto Tecnológico de Ciudad Madero, así como a todo el plantel, al Tecnológico Nacional de México, al programa CONACYT por el apoyo económico mediante la beca para lograr tener los recursos económicos para estudiar la maestría a mis amigos y a mis compañeros de programa que siempre estuvieron para ayudarme.

El uso de técnicas de aprendizaje Automático en aplicaciones del cambio climático.

Ing. Oscar Román Bozada Zúñiga

Resumen

El calentamiento global se ha convertido en uno de los problemas ambientales más importantes al día de hoy.

Si bien el cambio climático es un proceso que se ha dado naturalmente, el ser humano han sido el principal motor del cambio climático en la actualidad, principalmente por la quema de combustibles fósiles como el carbón, el petróleo y el gas.

Según la Agencia Internacional de la Energía (AIE), en el año 2021 se registró un envío de 2,000 millones de toneladas de CO₂ a la atmosfera, siendo principal fuente de esta emisión, la actividad del ser humano.

Debido a todo este daño ocasionado por el ser humano, el pronóstico del clima ha sido un tema de gran relevancia.

En las últimas décadas, se han empleado diferentes técnicas para encontrar un buen pronóstico, llegando a métodos matemáticos donde a partir de algoritmos y análisis de datos sobre una serie de tiempo, se logran obtener resultados muy cercanos al valor real.

Se han hecho investigaciones para combinar diferentes enfoques para construir modelos de pronóstico eficientes. Las comparaciones de estos modelos ayudan a determinar las fortalezas y debilidades del modelo. Se deben introducir ciertos criterios para medir la precisión de un modelo [1].

The use of machine learning techniques in climate change applications.

Ing. Oscar Román Bozada Zúñiga

Abstract

Global warming has become one of the most important environmental problems today.

Although climate change is a process that has occurred naturally, humans have been the main driver of climate change today, mainly due to the burning of fossil fuels such as coal, oil and gas.

According to the International Energy Agency (IEA), in 2021, 2,000 million tons of CO₂ were sent into the atmosphere, with human activity being the main source of this emission.

Due to all this damage caused by humans, climate forecasting has been a topic of great relevance.

In recent decades, different techniques have been used to find a good forecast, reaching mathematical methods where, based on algorithms and data analysis on a time series, results are obtained that are very close to the real value.

Research has been done to combine different approaches to build efficient forecasting models. Comparisons of these models help determine the strengths and weaknesses of the model. Certain criteria must be introduced to measure the accuracy of a model.

Índice General

Resumen.....	V
Abstract.....	VI
Índice tablas.....	IX
Índice de figuras	X
1 Introducción.....	1
1.1 Planteamiento del problema.....	2
1.2 Objetivo General.....	3
1.3 Objetivos específicos	3
1.4 Hipótesis	4
1.5 Justificación del estudio.....	4
1.6 Alcances.....	5
1.7 Limitaciones.....	5
1.8 Organización de la tesis.	5
2 Marco teórico	7
2.1 Acuerdo de París.....	7
2.2 Pronóstico	8
2.2.1 Áreas de aplicación de los pronósticos:	9
2.2.2 Retos y Limitaciones:	10
2.3 Redes Neuronales.....	10
2.4 Redes Neuronales Convolucionales.....	11
2.4.1 Antecedentes:	12
2.4.2 Arquitectura de una Red neuronal Convolutional:	12
2.4.3 Principales características de las CNNs:	13

2.5	Método CNN-CT	14
2.5.1	Transformación de datos	14
2.5.2	Estimaciones diarias	15
2.5.3	Transformación Residual	17
2.5.4	Pronóstico	17
2.6	Support Vector Regression (SVR)	17
2.7	Algoritmo Genético	18
2.7.1	Conceptos Fundamentales:	19
2.7.2	Funcionamiento de un Algoritmo Genético:	19
3	Antecedentes	21
4	Resultados	24
4.1	Usando CNN-CT	26
4.2	34	
4.3	Usando SVR con algoritmo genético	34
5	Conclusiones	36
	Bibliografía.....	37

Índice Tablas

Tabla 1. Ejemplificación de la asignación de subcomponentes	15
Tabla 2. Estado del arte	23
Tabla 3. Pronósticos sobre serie de datos mensuales	25
Tabla 4. Resultados CNN (Componentes trimestrales)	26
Tabla 5. Estimaciones mensuales (Componentes trimestrales)	27
Tabla 6. Resultados CNN (Componentes Cuatrimestrales)	27
Tabla 2. Estimaciones mensuales (Componentes cuatrimestrales)	28
Tabla 3. Resultados CNN (Componentes trimestrales)	28
Tabla 4. Estimaciones mensuales (Componentes semestrales)	29
Tabla 10. Serie de tiempo utilizada en validación y prueba	29
Tabla 11. explicación de la utilidad de residuales en la validación	31
Tabla 12. Resultados de sintonización de SVR mediante Algoritmo genético	35

Índice de Figuras

Figura 4.1. 1 Diagrama del método CNN-CT	14
Figura 2. Gráfica del pronóstico a 20 años mensuales.....	25
Figura 2. Grafica Resultados componentes trimestrales	27
Figura 3. Grafica Resultados componentes cuatrimestrales	28
Figura 5. Grafica Resultados componentes Semestrales	29
Figura 4. Resultados validación 20 años	30
Figura 5. Resultados validación 20 años después de residuales	31
Figura 6. Pronóstico de residuales utilizando Suavizamiento Exponencial Simple	32
Figura 9. Resultados de pronóstico en etapa de prueba a 20 años	32
Figura 10. Resultados del pronóstico en la etapa de prueba a 20 años después de residuales por suavizamiento exponencial simple	33
Figura 11. Resultados del pronóstico en la etapa de prueba a 20 años después de residuales por Holt&Winters	33

1 Introducción

El calentamiento global se ha convertido en uno de los problemas ambientales más importantes al día de hoy.

Si bien el cambio climático es un proceso que se ha dado naturalmente, el ser humano han sido el principal motor del cambio climático en la actualidad, principalmente por la quema de combustibles fósiles como el carbón, el petróleo y el gas.

Según la Agencia Internacional de la Energía (AIE), en el año 2021 se registró un envío de 2,000 millones de toneladas de CO₂ a la atmósfera, siendo principal fuente de esta emisión, la actividad del ser humano.

Debido a todo este daño ocasionado por el ser humano, el pronóstico del clima ha sido un tema de gran relevancia.

En las últimas décadas, se han empleado diferentes técnicas para encontrar un buen pronóstico, llegando a métodos matemáticos donde a partir de algoritmos y análisis de datos sobre una serie de tiempo, se logran obtener resultados muy cercanos al valor real.

Se han hecho investigaciones para combinar diferentes enfoques para construir modelos de pronóstico eficientes. Las comparaciones de estos modelos ayudan a determinar las fortalezas y debilidades del modelo. Se deben introducir ciertos criterios para medir la precisión de un modelo [1].

Entre los diferentes métodos utilizados, existen técnicas en base de Estadística y en base de aprendizaje automático, los cuales son las técnicas con mejores resultados obtenidos [2].

Métodos como “Auto Regressive Integrated Moving Average” (ARIMA), las regresiones múltiples y el suavizamiento exponencial son ejemplos de métodos estadísticos útiles para estos estudios, mientras que métodos como los algoritmos genéticos, la inferencia difusa, las redes neuronales, regresión de vectores de soporte etc. pertenecen a modelos de aprendizaje automático capaces de entregar buenos resultados [3].

La principal diferencia entre los dos tipos de métodos mencionados, es que los estadísticos generalmente se asocian con datos lineales, mientras que los métodos de aprendizaje automático se relacionan con datos no lineales [3].

Muchos investigadores adoptaron diferentes enfoques para mejorar la precisión del modelo, esto se ha logrado gracias a la implementación de modelos híbridos [4].

Los modelos híbridos se pueden clasificar en modelos similares y diferentes. La integración de dos o más modelos lineales/no lineales entra en la categoría de modelos similares, mientras que la combinación de modelos lineales y no lineales se denomina modelos diferentes [4].

1.1 Planteamiento del problema

El cambio climático global se convirtió en un problema social ampliamente aceptado. Conocido también como efecto invernadero antropogénico, es el aumento perceptible en la temperatura global media como resultado de la liberación de gases de efecto invernadero producidos por las actividades humanas. La conciencia de esta amenaza global reforzó la preocupación pública por los problemas ambientales y, por lo tanto, proporcionó a los activistas ambientales, científicos y legisladores un nuevo impulso en sus esfuerzos por promover la protección ambiental [5].

La naturaleza caótica de la atmósfera implica que todos los pronósticos son inciertos. El grado de incertidumbre depende de las características del modelo numérico utilizado, y también de la estación, la ubicación geográfica y la situación climática [6].

Se proyecta que el calentamiento global tendrá una amplia gama de impactos en el estado medio y la variabilidad de la atmósfera y puede afectar una serie de características relacionadas con la previsibilidad atmosférica. Estos incluyen la intensidad y la variabilidad estacional en la actividad de la trayectoria de las tormentas, así como las características dinámicas de los principales modos de variabilidad climática en latitudes medias [6].

A pesar de esto, todavía carecemos de una comprensión sólida de cómo la incertidumbre intrínseca de los pronósticos meteorológicos a mediano plazo puede verse afectada por estos cambios. Los escenarios detallados de situaciones climáticas futuras son valiosos, y los cambios significativos en nuestra capacidad para pronosticar el clima, incluidos los eventos extremos, tendrían profundas implicaciones para el diseño de políticas de adaptación y de futuros servicios de respuesta a emergencias [6].

Cuantificar la incertidumbre de los pronósticos meteorológicos es una tarea compleja. Uno de los métodos más utilizados es la predicción meteorológica por conjuntos, aunque se han propuesto metodologías alternativas. Un pronóstico por conjuntos implica producir un conjunto de diferentes pronósticos dada una situación meteorológica inicial [6].

Una de las técnicas en la cual se observan buenos resultados, son las técnicas basadas en aprendizaje automático [2], las cuales, para en un término de mediano plazo (de 5 a 20 años), se aplicarán a un pronóstico de la variable de temperatura en la zona de México centro, para así lograr observar el comportamiento al cual se verá afectada esta variable en dicho plazo lo cual nos indicará la tendencia que se llevará en el cambio climático.

Se plantea entonces, realizar un ensamble de tipo de técnicas de aprendizaje, para realizar un pronóstico del cambio climático del cual se esperan resultados cercanos a los entregados por el estado del arte.

1.2 Objetivo General

Generar un pronóstico a corto y mediano plazo, de la variable de temperatura en la zona centro de México, haciendo uso de técnicas de aprendizaje automático.

1.3 Objetivos específicos

1. Hacer uso de las técnicas de aprendizaje automático.
2. Obtener resultados parecidos a los entregados por el estado del arte.
3. Generar un ensamble de algoritmos y compararlo con los métodos individuales.
4. Utilizar el método CNN-CT en el ensamble de métodos.

1.4 Hipótesis

Las técnicas de aprendizaje automático pueden entregar buenos resultados a mediano plazo sobre la variable de temperatura.

1.5 Justificación del estudio

El calentamiento global se ha convertido en uno de los problemas ambientales más importantes de hoy en día, tanto mundialmente como nacionalmente, México forma parte del acuerdo de París donde se comprometió junto con otros países, a hacer frente al cambio climático y el calentamiento global, con los siguientes compromisos específicos en un rango de 10 años (2020 a 2030) los cuales son:

- Reducir la emisión de compuestos y gases de efecto invernadero en un 22% y de carbono negro en un 51%.
- Incrementar la capacidad adaptativa de la población y disminuir su vulnerabilidad ante el cambio climático.
- Conservación, restauración y manejo sustentable de ecosistemas.
- Alcanzar la tasa cero de deforestación.
- Generar alertas tempranas de prevención ante eventos climáticos extremos.

La importancia de pronosticar el cambio climático es prioridad para la humanidad, para entender el daño que se causa al medio ambiente y obtener resultados que sirvan de ayuda para actuar y poder contrarrestar el cambio del clima que puede significar una amenaza significativa al planeta.

Se tomará como variable a analizar la temperatura, ya que a medida que las emisiones de gases de efecto invernadero cubren la Tierra, atrapan el calor del sol, lo que conduce al calentamiento global y al cambio climático. El mundo se calienta ahora más rápido que en cualquier otro momento de la historia del que haya registros. Con el tiempo, las temperaturas más cálidas están cambiando los patrones climáticos y alterando el equilibrio normal de la naturaleza.

Con este trabajo, se busca contribuir tanto para el país como mundialmente, demostrando no solo resultados de pronóstico de temperatura para mediano plazo, sino brindando

información sobre los métodos de aprendizaje utilizados y el mejor obtenido en cuestión de generación de pronósticos.

1.6 Alcances

- Emplear librerías y herramientas entregadas por los softwares que ayuden a un mejor resultado.
- Implementar ensamble de métodos.
- Obtener resultados con un horizonte de pronóstico de al menos 5 años.
- Identificar el mejor método que se utilizó en base a los resultados.

1.7 Limitaciones

- Series de tiempo con entradas mensuales.
- Resultados entregados en forma mensual, trimestral, cuatrimestral o semestral.
- Series de tiempo de entrenamiento acotadas a 100 años.

1.8 Organización de la tesis.

En el capítulo 1, se establecen tanto las ideas como los métodos a seguir para abordar la importancia de la tesis, se divide en 5 subcapítulos donde cada uno explica un punto clave a considerar en la realización del proyecto.

En el subcapítulo 1.1 se plantea el problema que se aborda en este proyecto, se aborda la importancia de realizar estos estudios para el avance tecnológico y que el ser humano obtenga más herramientas para monitorear y prevenir los cambios climáticos a mediano plazo. También se describen los problemas actuales en los que mundialmente se combaten y se planea que el proyecto sea útil para aportar en las organizaciones que se encargan de este combate contra los problemas ambientales.

En el subcapítulo 1.2 se describe la importancia de realizar este tipo de proyectos, dando a conocer los antecedentes que se ha ocasionado en el planeta, dando la necesidad de crear las herramientas para combatir los cambios climáticos futuros y

dando un indicio sobre cómo se ve presentado el futuro de acuerdo al pronóstico generado.

En el subcapítulo 1.3 Se dan a conocer los objetivos tanto general como los específicos de los cuales se enfocó el proyecto realizado cubriendo con ellos obteniendo los resultados planteados.

En el subcapítulo 1.4 se establece la acotación del proyecto, las cuales son para el caso de lo que se puede realizar en manera de lo necesario la lista de alcances y para el caso de los recursos que no estarán disponibles o estarán establecidos sin modificar, los encontramos en la lista de limitaciones.

En el subcapítulo 1.4 se describe la hipótesis a demostrar.

En el capítulo 2 se abarca todo el material antecedente a este trabajo, explicando puntualmente las técnicas utilizadas para el proyecto, tantas herramientas, trabajos anteriores, conceptos sobre el tema y las necesidades que se requieren abarcar en este tipo de proyectos.

En el capítulo 3 se habla sobre el estado del arte, donde observamos trabajos que brindan información útil, ya que cuentan con la implementación de métodos de aprendizaje automático para generar pronósticos de variables del cambio climático.

En el capítulo 4 se demuestran los resultados obtenidos al realizar el proyecto en las diferentes variantes y opciones que se demuestran en el capítulo, se demuestra todo el experimento realizado y se explican en cada caso las variantes realizadas.

Por último, en el capítulo 5 se muestran las conclusiones obtenidas al realizar el proyecto, las cuales demuestran que los resultados obtenidos logran los objetivos planteados para el proyecto.

2 Marco teórico

2.1 Acuerdo de París

Existe un acuerdo generalizado entre los científicos de que la temperatura global ha estado aumentando durante las últimas décadas. Este aumento es atribuido principalmente a la actividad humana, especialmente la emisión de gases de efecto invernadero, como el dióxido de carbono (CO₂).

El Acuerdo de París es un tratado internacional adoptado en diciembre de 2015 en la Cumbre del Clima de las Naciones Unidas (COP21) en París, Francia. Su objetivo principal es abordar el cambio climático y limitar el aumento de la temperatura global a niveles que sean seguros para el planeta.

El objetivo principal del Acuerdo de París es mantener el aumento de la temperatura global muy por debajo de 2 grados Celsius por encima de los niveles preindustriales y esforzarse por limitarlo a 1.5 grados Celsius. Esto se considera crucial para evitar impactos climáticos catastróficos.

La falta de una temperatura específica de referencia en grados Celsius se debe a la dificultad de determinar con precisión cuál fue la temperatura promedio global en la era preindustrial. Dado que no existen registros de temperatura precisos de esa época, el acuerdo utiliza la

expresión "niveles preindustriales" como un término general para referirse a un período anterior a la industrialización significativa, que comenzó en el siglo XVIII.

El enfoque en la temperatura global en el Acuerdo de París refleja su importancia como indicador clave del cambio climático y su impacto en la salud del planeta y de las personas. Limitar el aumento de la temperatura es fundamental para evitar los efectos más graves del cambio climático y garantizar un futuro sostenible para todos.

El Acuerdo de París es relevante para los pronósticos de temperatura y la planificación relacionada con el clima porque establece objetivos de temperatura a largo plazo, influye en las políticas y acciones de mitigación, y aumenta la concienciación y la acción pública en relación con el cambio climático. Los pronósticos de temperatura deben tener en cuenta estos factores para proporcionar una visión precisa y relevante del futuro climático.

2.2 Pronóstico

Un pronóstico se refiere a una declaración o evaluación anticipada del futuro, basada en la recopilación y análisis de datos y evidencia relevante. Su objetivo principal es proporcionar información útil y razonablemente precisa sobre eventos futuros o tendencias. Los pronósticos se utilizan en una amplia variedad de campos y situaciones para respaldar la toma de decisiones, la planificación y la gestión de recursos. A continuación, exploraremos varios aspectos clave relacionados con los pronósticos:

Proceso de Pronóstico: En la literatura científica, se enfatiza la importancia de que los pronósticos sean el resultado de un proceso metódico y sistemático. Esto implica la recopilación de datos históricos relevantes, la identificación de patrones y tendencias, y la aplicación de modelos y métodos estadísticos apropiados para predecir eventos futuros.

Horizonte de Pronóstico: El horizonte de pronóstico se refiere al período de tiempo en el que se espera que se cumplan las predicciones. Puede variar desde pronósticos a corto plazo, que abarcan solo unos pocos días o semanas, hasta pronósticos a largo plazo que pueden abarcar varios años o décadas.

Incertidumbre: En la literatura científica, se reconoce que todos los pronósticos están sujetos a algún grado de incertidumbre. Los pronósticos no pueden predecir con certeza absoluta el futuro, ya que los eventos futuros pueden estar influenciados por múltiples factores impredecibles.

Métodos de Pronóstico: Diversos campos utilizan métodos específicos para realizar pronósticos. Estos métodos pueden incluir técnicas estadísticas, modelos matemáticos, aprendizaje automático y enfoques basados en la experiencia experta. La elección del método depende del contexto y de la disponibilidad de datos.

Evaluación de Pronósticos: En la literatura científica, se enfatiza la importancia de evaluar la calidad de los pronósticos. Esto implica comparar las predicciones con los resultados reales y utilizar métricas como el error medio cuadrado o el error absoluto medio para determinar la precisión del pronóstico.[7]

2.2.1 Áreas de aplicación de los pronósticos:

Economía: Los pronósticos económicos se utilizan para prever tendencias en el crecimiento económico, tasas de inflación, tipos de cambio y mercados financieros.

Meteorología: Los pronósticos meteorológicos son esenciales para predecir el clima, tormentas, huracanes y condiciones climáticas adversas.

Gestión de la Cadena de Suministro: Los pronósticos ayudan a las empresas a planificar la producción y el inventario, optimizando la cadena de suministro.

Salud Pública: Se utilizan para predecir brotes de enfermedades, la propagación de epidemias y la demanda de servicios de atención médica.

Ingeniería y Construcción: Los pronósticos se aplican en la planificación de proyectos de construcción y la gestión de recursos.[7]

2.2.2 Retos y Limitaciones:

La incertidumbre inherente en los pronósticos puede dar lugar a errores significativos, lo que resalta la importancia de la actualización y revisión de pronósticos a medida que se disponga de nueva información.

La calidad de los pronósticos depende en gran medida de la disponibilidad y calidad de los datos históricos utilizados.

Los pronósticos a largo plazo son especialmente susceptibles a la incertidumbre y pueden requerir la inclusión de múltiples escenarios posibles. [7].

2.3 Redes Neuronales

Las redes neuronales, son modelos matemáticos inspirados en el funcionamiento del cerebro humano. Son una parte fundamental del aprendizaje profundo (deep learning), un subcampo de la inteligencia artificial que se centra en entrenar sistemas informáticos para aprender y realizar tareas complejas, como el reconocimiento de patrones, la toma de decisiones y la resolución de problemas.

Las redes neuronales están compuestas por unidades interconectadas llamadas neuronas artificiales o nodos.

Estas neuronas están organizadas en capas, generalmente divididas en tres tipos: la capa de entrada, la capa oculta y la capa de salida. Cada neurona recibe entradas, realiza cálculos en función de esas entradas y luego emite una salida. La información fluye desde la capa de entrada a través de las capas ocultas hasta la capa de salida. La clave de las redes neuronales es aprender a ajustar los pesos y los sesgos de las conexiones entre las neuronas para que el modelo sea capaz de realizar la tarea deseada [8].

los componentes y el funcionamiento de las redes neuronales son:

Neurona artificial (Perceptrón): Cada neurona artificial es una unidad de procesamiento que toma una serie de entradas (números) y aplica una función matemática para calcular una salida. La función más comúnmente utilizada es la función de activación, que introduce no

linealidad en la red. Las entradas están ponderadas por pesos, y la suma de estas entradas ponderadas se pasa a través de la función de activación. El resultado es la salida de la neurona.

Conexiones entre neuronas: Las neuronas están conectadas mediante conexiones ponderadas. Los pesos son valores numéricos que ajustan la influencia de una neurona en la siguiente. El proceso de entrenamiento de la red implica ajustar estos pesos para que la red produzca las salidas deseadas para un conjunto dado de entradas.

Capas: Las redes neuronales están organizadas en capas. La capa de entrada recibe datos del entorno o del conjunto de datos que se está procesando. Las capas ocultas realizan cálculos intermedios, y la capa de salida produce la salida final del modelo.

Función de activación: Como se mencionó anteriormente, las neuronas aplican una función de activación a la suma ponderada de sus entradas. Esto introduce no linealidad en el modelo, lo que permite a la red aprender y representar relaciones complejas en los datos. Ejemplos de funciones de activación incluyen la función sigmoide, la función ReLU (Rectified Linear Unit) y muchas otras.

Aprendizaje: El proceso de aprendizaje en una red neuronal implica ajustar los pesos y los sesgos de las conexiones entre las neuronas para minimizar la diferencia entre las salidas reales y las salidas deseadas para un conjunto de datos de entrenamiento. Esto se hace utilizando algoritmos de optimización, como el descenso del gradiente, que actualizan los pesos en función de la dirección en la que se reduce el error [9].

2.4 Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales (Convolutional Neural Networks o CNNs por sus siglas en inglés) son un tipo de arquitectura de redes neuronales profundas diseñadas específicamente para tareas de visión por computadora, como el reconocimiento de imágenes, segmentación semántica, detección de objetos y muchas otras aplicaciones

relacionadas con el procesamiento de datos visuales. A lo largo de esta explicación extensa, exploraremos en detalle qué son las CNNs, cómo funcionan y por qué son tan eficaces en el procesamiento de imágenes [10].

2.4.1 Antecedentes:

El desarrollo de las CNNs se remonta a la década de 1980, pero fue en la década de 2010 cuando se popularizaron y alcanzaron su máximo potencial. Uno de los hitos más destacados fue la victoria del equipo de Geoffrey Hinton en la competición ImageNet Large Scale Visual Recognition Challenge en 2012, utilizando una CNN llamada "AlexNet". Esto marcó un punto de inflexión en la investigación en visión por computadora y el aprendizaje profundo.

2.4.2 Arquitectura de una Red neuronal Convolutiva:

Las CNNs se inspiran en la organización de la corteza visual del cerebro humano, donde las neuronas responden a regiones locales del campo visual. La característica distintiva de las CNNs es la capa de convolución, que lleva a cabo la operación de convolución.

Capa de convolución: En esta capa, se aplican filtros (kernels) a una imagen de entrada. Los filtros son pequeñas matrices numéricas que se deslizan por la imagen para calcular productos escalares locales. Esto permite a la CNN aprender patrones locales en la imagen, como bordes, texturas y otros detalles.

Capa de activación: Después de la convolución, se aplica una función de activación no lineal (generalmente ReLU - Rectified Linear Unit). La función ReLU introduce no linealidad en la red y ayuda a aprender características más complejas.

Capa de pooling (subsampling): Esta capa reduce la dimensionalidad de la representación al reducir el tamaño de las características muestreadas. La operación de pooling (por ejemplo,

max-pooling) selecciona el valor máximo de un grupo de valores en una región local. Esto reduce la cantidad de cálculos y, al mismo tiempo, conserva las características más importantes.

Capa completamente conectada: Al final de la CNN, se utilizan capas completamente conectadas, similares a las de una red neuronal feedforward tradicional, para realizar la clasificación o regresión final. Estas capas pueden procesar las características extraídas de la imagen y realizar tareas específicas [11].

2.4.3 Principales características de las CNNs:

Invariancia espacial: Las CNNs son capaces de reconocer patrones en una imagen independientemente de su ubicación, lo que las hace robustas a las transformaciones espaciales.

Jerarquía de características: A medida que se profundiza en las capas de una CNN, las características se vuelven más abstractas y complejas. Las primeras capas detectan bordes y texturas, mientras que las capas posteriores pueden reconocer objetos completos o características específicas.

Transferencia de aprendizaje: Las CNNs entrenadas en grandes conjuntos de datos, como ImageNet, se pueden utilizar como modelos base para tareas de visión por computadora específicas con un ajuste fino (fine-tuning). Esto ahorra tiempo y recursos de entrenamiento.

Aplicaciones diversas: Las CNNs se utilizan en una amplia variedad de aplicaciones, desde el reconocimiento de objetos y el procesamiento de imágenes médicas hasta la generación de arte generativo [12].

2.5 Método CNN-CT

Es un método basado en una red neuronal convolucional y una transformación de componentes temporal, 2 fases de training, la primera fase corresponde al método de pronóstico usando valores de componentes, y la segunda fase, al uso de valores residuales con un método de pronóstico residual [13].

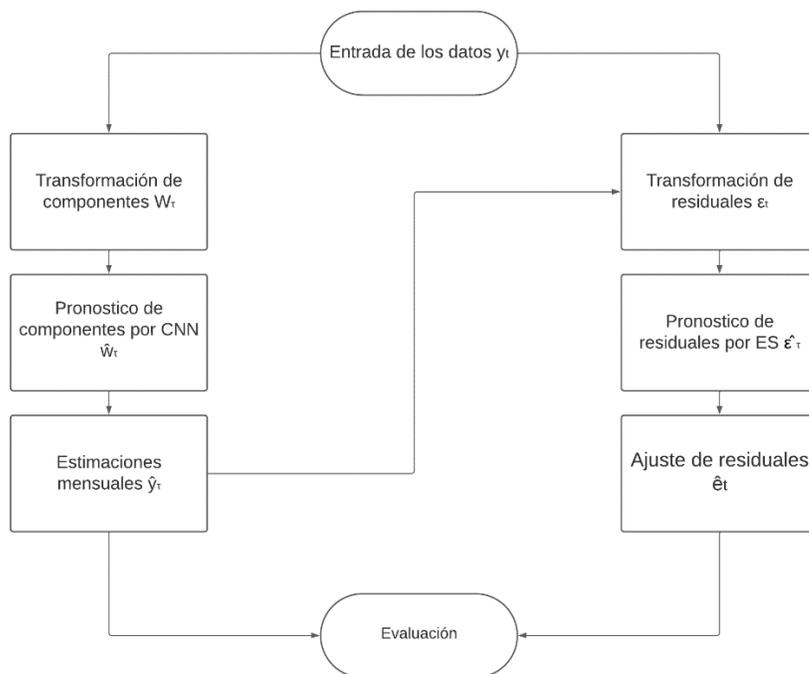


Figura 7 Diagrama del método CNN-CT

2.5.1 Transformación de datos

Se utiliza una transformación de componentes para así, transformar casos diarios en componentes semanales, mapeando los casos diarios y_t en componentes w_t , los cuales son un promedio ponderado de los casos diarios.

Este proceso se logra gracias a la siguiente ecuación:

$$w_{\tau} = \frac{\sum_{t=7\tau-6}^{7\tau} y_t}{7}$$

Se utiliza una CNN como método de pronóstico de componentes. Las etapas de entrenamiento y validación están compuestas por valores de w_{τ} .

2.5.2 Estimaciones diarias

Realizar estimaciones diarias, implica convertir de nuevo los componentes semanales en valores diarios. Para esto, se necesita calcular los subcomponentes de estos componentes.

Semana w_{τ}						
subcomponente $\delta_{\tau,1}$				subcomponente $\delta_{\tau,2}$		
Lunes	Martes	Miércoles	Jueves	Viernes	Sábado	Domingo

Tabla 5 Ejemplificación de la asignación de subcomponentes.

La distribución de los casos diarios con respecto a sus subcomponentes se puede obtener mediante las siguientes ecuaciones:

$$\delta_{\tau,1} = \frac{\sum_{t=1,\tau}^{4,\tau} y_{t,\tau}}{4}$$

$$\delta_{\tau,2} = \frac{\sum_{t=5,\tau}^{7,\tau} y_{t,\tau}}{3}$$

Se determina que la razón diaria $\mu_{\tau,t}$ representa la proporción de los valores diarios originales para el subcomponente 1 y 2 para el componente τ .

$$\mu_{\tau,t} = \begin{cases} \frac{y_{\tau,t}}{\delta_{\tau,1}}, & \text{if } 1 \leq t \leq 4 \\ \frac{y_{\tau,t}}{\delta_{\tau,2}}, & \text{if } 5 \leq t \leq 7 \end{cases}$$

El ratio diario $\mu_{\tau,t}$ nos permite determinar los casos normalizados entre semana x_t de la fase de entrenamiento.

$$x_t = \frac{\sum_{i=1}^{\tau} \mu_i}{\tau}$$

La transformación inversa determina los datos diarios pronosticados a partir de los componentes usando las siguientes ecuaciones:

$$\hat{\delta}_{\tau,i} = \hat{w}_{\tau} \frac{w_{\tau}}{\delta_{\tau,i}}$$

$$\hat{y}_{\tau,t} = \begin{cases} x_t \hat{\delta}_{\tau,1}, & \text{if } 1 \leq t \leq 4 \\ x_t \hat{\delta}_{\tau,2}, & \text{if } 5 \leq t \leq 7 \end{cases}$$

Donde:

$\hat{y}_{\tau,t}$ representa los valores del componente τ en el tiempo t

$\hat{\delta}_{\tau,i}$ es el pronóstico del número promedio de subcomponentes i en el componente τ

2.5.3 Transformación Residual

Un valor residual es dado por la siguiente formula:

$$e_t = y_t - \hat{y}_t = y_t - y_{t-1}$$

Los residuos e_t se obtienen restando y_t de $y_{\tau,t}$

$$\varepsilon_t = |y_{\tau,t} - y_t|$$

Se utilizan estos residuales con ARIMA y ES, donde se obtienen 4 medios Híbridos, CNN-ARIMA, CNN-ES, LSTM-ARIMA y LSTM-ES.

2.5.4 Pronóstico

Los pronósticos $\varepsilon_{t,es}$ y $\varepsilon_{t,arima}$ de estos métodos híbridos se transforman en residuales $e_{t,es}, e_{t,arima}$, que se encuentran en el dominio no normalizado.

Finalmente, se evalúan los valores de pronóstico de la fase de validación F'_t , con la siguiente formula:

$$F'_t = y_{\tau,t} + e_{t,best}$$

2.6 Support Vector Regression (SVR)

Es un algoritmo de regresión no paramétrico que se basa en vectores de soporte y que se utiliza para predecir valores continuos.

Se puede entender como una extensión del SVM (Support Vector Machine) para el problema de regresión, en el que se busca predecir valores numéricos en lugar de clasificar los datos en categorías. El modelo se entrena con un conjunto de datos de entrenamiento que incluye tanto las variables de entrada como los valores correspondientes de la variable objetivo. El

objetivo del modelo es encontrar una función de regresión que mejor se ajuste a los datos de entrenamiento, mientras se minimiza el error de predicción en nuevos datos.

Utiliza una función de kernel para mapear los datos de entrada en un espacio de alta dimensión en el que se puede encontrar una superficie de regresión lineal o no lineal. Los vectores de soporte son los puntos de datos más importantes que ayudan a definir la superficie de regresión [14].

Este algoritmo y para este trabajo, utiliza 3 parámetros sintonizable los cuales se deben ajustar para cada una de las series de tiempo en las que se vaya a emplear, estos parámetros son:

Coste (C): Este parámetro controla la complejidad del modelo. Un valor alto de C indica que se penalizarán más los errores, lo que lleva a un modelo más complejo que se ajusta mejor a los datos de entrenamiento, pero puede ser más propenso al sobreajuste. Por otro lado, un valor bajo de C indica que se permiten más errores, lo que lleva a un modelo más simple y generalizable [15].

Kernel: El kernel es una función matemática que se utiliza para transformar los datos de entrada en un espacio de mayor dimensión. Esto permite que los datos sean más separables y, por lo tanto, más fáciles de modelar. Hay varios tipos de kernel disponibles, como el lineal, el polinómico y el radial, cada uno con sus propias ventajas y desventajas [16].

Epsilon (ϵ): Este parámetro controla la holgura permitida en la región de decisión del modelo. Un valor alto de ϵ permite que más puntos caigan dentro de la región de decisión, lo que lleva a un modelo más tolerante a los errores, mientras que un valor bajo de ϵ da como resultado un modelo más estricto que es menos tolerante a los errores [17].

2.7 Algoritmo Genético

Los Algoritmos Genéticos (AG) son un tipo de algoritmo de optimización y búsqueda basado en la evolución biológica. Fueron desarrollados por John Holland y sus colaboradores en la década de 1960 y se han convertido en una poderosa herramienta para resolver una amplia variedad de problemas de optimización, diseño y búsqueda en ciencia, ingeniería,

computación y otras disciplinas. A lo largo de esta explicación extensa, exploraremos en detalle qué son los Algoritmos Genéticos, cómo funcionan y cuáles son sus aplicaciones.

2.7.1 Conceptos Fundamentales:

Inspiración Biológica: Los Algoritmos Genéticos están inspirados en la teoría de la evolución de Charles Darwin. En la naturaleza, las especies evolucionan a lo largo del tiempo mediante la selección natural, donde los individuos con características beneficiosas tienen una mayor probabilidad de sobrevivir y reproducirse, transmitiendo sus genes a la siguiente generación. De manera similar, en un AG, se crea una población de soluciones candidatas y se les permite evolucionar hacia soluciones óptimas.

Codificación de Soluciones: Para aplicar un AG a un problema, es necesario codificar las soluciones posibles en forma de cromosomas, que son estructuras de datos que representan las soluciones candidatas. Estos cromosomas están formados por genes, que codifican características o variables del problema.

2.7.2 Funcionamiento de un Algoritmo Genético:

Un Algoritmo Genético opera siguiendo una serie de pasos generales:

Inicialización: Se genera una población inicial de soluciones candidatas de manera aleatoria o siguiendo ciertas heurísticas.

Evaluación: Cada solución en la población se evalúa mediante una función objetivo que mide su calidad en relación con el problema que se está resolviendo.

Selección: Se seleccionan soluciones de la población actual para formar una población de padres. Las soluciones con un mejor rendimiento tienen una mayor probabilidad de ser seleccionadas, pero se permite cierta aleatoriedad para mantener la diversidad.

Cruzamiento (crossover): Los cromosomas de los padres seleccionados se combinan para crear una población de descendientes. El cruzamiento simula la recombinación genética en la evolución natural.

Mutación: Ocasionalmente, se aplica una mutación a algunos de los cromosomas de la población de descendientes. La mutación introduce cambios aleatorios en los genes, lo que aumenta la diversidad genética.

Reemplazo: Se selecciona una población de supervivientes a partir de la población de descendientes y, posiblemente, la población anterior. Esto se hace utilizando un método como el reemplazo generacional o el reemplazo por elitismo, donde se conservan las mejores soluciones.

Convergencia: El proceso de selección, cruzamiento, mutación y reemplazo se repite durante un número fijo de generaciones o hasta que se cumpla un criterio de convergencia.

Principales Características de los Algoritmos Genéticos:

Exploración y Explotación: Los AG equilibran la exploración (buscar en diferentes áreas del espacio de soluciones) y la explotación (enfocarse en las mejores soluciones conocidas) a través de la selección y la mutación.

Adaptación: Los AG se adaptan con el tiempo, ya que las soluciones prometedoras tienen una mayor probabilidad de reproducirse y mejorar la población.

Paralelismo: Los AG son naturalmente paralelizables, lo que permite el uso de recursos computacionales distribuidos.

3 Antecedentes

En el artículo "Detection and Prediction of Natural Hazards Using Large-Scale Environmental Data" de Hubig, N., Fengler, P., Züfle, A., Yang, R., y Günnemann, S. (2017) se describe un enfoque para la detección y predicción de desastres naturales utilizando grandes cantidades de datos ambientales. El enfoque se basa en técnicas de aprendizaje automático y análisis estadístico aplicados a datos de sensores y otros datos ambientales.

En el artículo "Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets" de Liu et al. (2019) describe el uso de redes neuronales convolucionales profundas (DCNN) para detectar eventos climáticos extremos en conjuntos de datos climáticos. Los autores entrenaron y evaluaron el modelo utilizando un conjunto de datos global de temperatura del aire en superficie y precipitación, y se centraron en la detección de eventos de calor extremo y sequía.

El modelo logró una precisión de detección de eventos de calor extremo del 96.8% y una precisión de detección de eventos de sequía del 97.6%.

En el artículo "Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast" de Hossain y Mahmood (2020) describe un modelo de pronóstico de energía solar fotovoltaica utilizando una red neuronal de memoria a largo plazo

(LSTM) y pronósticos meteorológicos sintéticos. El modelo se utiliza para predecir la producción de energía solar a corto plazo en una instalación fotovoltaica, logrando un MAPE de 22.31%.

En el artículo "Weather Forecasting using Deep Learning Techniques" de Salman et al. (2018) describe el uso de técnicas de aprendizaje profundo para predecir el clima. Los autores utilizaron datos históricos de temperatura, humedad, velocidad del viento y presión atmosférica para entrenar y evaluar diferentes modelos de redes neuronales profundas (DNN).

Los resultados del estudio muestran que el modelo de red neuronal convolucional (CNN) superó a otros modelos en términos de precisión de predicción. En particular, los autores encontraron que el modelo CNN logró una precisión del 91.76% en la predicción de la temperatura.

A continuación, se muestra la tabla resumen de los artículos hablados anteriormente, donde se observan las características de cada uno como su año de publicación, las variables estudiadas, los métodos de predicción empleados y las herramientas utilizadas en cada trabajo.

Autores	Artículo	Año	Variables	Modelo	Herramienta	DataSet
Yunjie Liu, Evan Racah, Prabhat, J oaquin Correa, Amir Khosrowshahi, David Lavers, Kenneth Kunkel, Michael Wehner, William Collins	Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets [19]	2016	Temperatura	Convolutional Neural Networks	Edison, Cray XC30 and Cori, Cray XC40	ERA-Interim reanalysis
Nina Hubig, Philip Fengler, Andreas Züfle, Ruixin Yang & Stephan Günemann	Detection and Prediction of Natural Hazards Using Large-Scale Environmental Data [20]	2017	Temperatura, Viento, Humedad	CTTF 4MTF	MATLAB	MERRA
Mohammad Safayet Hossain, Hisham Mahmood	Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast [21]	2020	Temperatura, Viento, Humedad	LSTM Neuronal Network	No mencionada	weather forecast channel
Afan Galih Salman; Bayu Kanigoro; Yaya Heryadi	Weather Forecasting using Deep Learning Techniques [22]	2015	Temperatura, Humedad, precipitacion	Recurrence Neural Network, Conditional Restricted Boltzmann Machine, Convolutional Network	No mencionada	BMKG

Tabla 2. Estado del arte

4 Resultados

Utilizando CNN

Se realizó la primera prueba de este método al pronosticar la serie de tiempo utilizando únicamente la red neuronal convolucional sobre los datos de entrenamiento a 20 años de prueba en resultados, en este caso no se emplean los métodos de transformación de componentes ni de residuales por lo que obtenemos como resultado 240 meses como pronóstico directo de la red neuronal sin ajustar el resultado.

Obteniendo los siguientes resultados para los años del 2001 al 2021:

	Año 2002	Año 2003	Año 2004	Año 2005	Año 2006	Año 2007	Año 2008	Año 2009	Año 2010	Año 2011
Enero	15.404642	15.344291	15.363607	15.427995	15.406513	15.520225	15.450528	15.432245	15.314982	15.411387
Febrero	16.985289	16.57386	16.779486	16.785318	16.708094	16.978329	16.858603	16.891088	16.733662	16.779003
Marzo	19.075108	18.906527	19.104065	19.07582	19.10743	19.074158	18.943647	19.18668	18.940619	19.056778
Abril	21.79637	21.754393	21.819338	21.788332	21.73112	21.850954	21.641972	21.897442	21.672558	21.932238
Mayo	24.056494	23.95273	24.162695	24.054401	24.071404	24.101126	24.07993	24.143854	23.976574	24.27401
Junio	25.172642	25.094269	25.240261	25.086655	25.265783	25.235157	25.04116	25.210796	25.02645	25.10351
Julio	24.895388	24.849993	25.106623	25.107021	25.022524	24.954456	24.928652	24.897882	24.944271	24.898098
Agosto	24.550554	24.563334	24.69662	24.827671	24.729456	24.69883	24.756905	24.822512	24.764692	24.65431
Septiembre	23.555948	23.653225	23.610474	23.718918	23.728754	23.693462	23.771267	23.615803	23.771267	23.586477
Octubre	20.860765	20.858961	20.856356	20.953848	21.13119	20.848997	20.997408	20.717127	20.847414	20.740513
Noviembre	17.205341	17.368195	17.41617	17.522337	17.580145	17.438429	17.41123	17.435389	17.549665	17.460855
Diciembre	15.265861	15.381689	15.510332	15.534353	15.548249	15.339025	15.522195	15.329345	15.325085	15.443089

Capítulo 4. Resultados

	Año 2012	Año 2013	Año 2014	Año 2015	Año 2016	Año 2017	Año 2018	Año 2019	Año 2020	Año 2021
Enero	15.237223	15.267603	15.359576	15.383009	15.344789	15.39204	15.463443	15.321429	15.442517	15.353327
Febrero	16.725388	16.82875	16.762833	16.901016	16.891512	16.877203	16.985624	16.80208	16.941425	16.849033
Marzo	19.024841	18.988142	18.99425	19.047468	19.212801	19.1965	18.9752	19.08875	19.156292	19.067247
Abril	21.942244	21.799597	21.76869	21.772923	21.847328	21.91647	21.874115	21.73364	21.778172	21.863611
Mayo	24.163519	24.093782	24.08221	24.12131	24.136618	24.159409	24.134008	24.118513	24.14938	24.126354
Junio	25.045448	25.212807	25.149643	25.152315	25.308516	25.2722	25.194338	25.232346	25.142773	25.26839
Julio	25.143602	25.113808	25.001053	25.046331	25.100714	24.996769	25.111753	25.244667	25.034777	25.091051
Agosto	24.84621	24.719471	24.740864	24.79138	24.828907	24.778831	24.802286	24.784496	24.803734	24.737747
Septiembre	23.577314	23.610352	23.727097	23.768097	23.567213	23.753073	23.643948	23.58698	23.551804	23.600483
Octubre	20.918377	20.789557	20.768736	20.991684	20.953623	21.06712	21.031986	20.98277	20.882114	20.884768
Noviembre	17.57661	17.439697	17.47818	17.532534	17.570992	17.652708	17.562906	17.495955	17.584438	17.524424
Diciembre	15.43808	15.35072	15.356237	15.293778	15.397418	15.465141	15.427377	15.481732	15.43147	15.360634

Tabla 7 Pronósticos sobre serie de datos mensuales.

Donde gráficamente se puede observar la comparación de la gráfica real con la gráfica pronosticada:

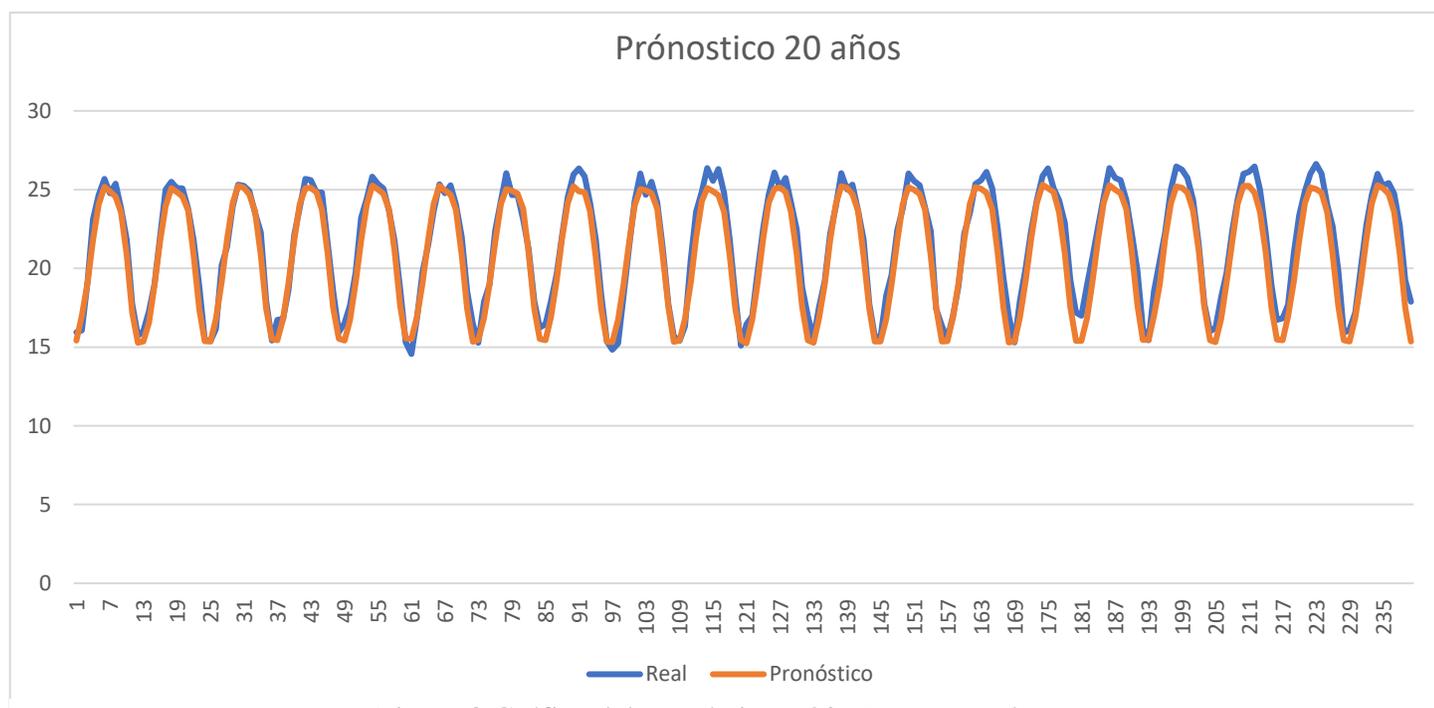


Figura 8 Gráfica del pronóstico a 20 años mensuales.

Al comparar ambas series, obtenemos un error MAPE de 3.60%.

4.1 Usando CNN-CT

Se realizó la primera prueba de este proyecto ingresando una línea de tiempo de 113 años (de 1901 al 2014) a una red neuronal convolucional donde para resultados a 5 años, se tomaron diferentes resultados conforme a los datos de entrada, los cuales se variaron en función de componentes por año.

Caso sin componentes: En este caso se utilizaron datos mensuales sin componentes.

Primer caso: Componentes trimestrales (4 componentes por año).

Segundo caso: Componentes cuatrimestrales (3 componentes por año).

Tercer caso: Componentes semestrales (2 componentes por año).

Con estos resultados, Se obtuvieron valores aproximados para cada mes en un intervalo de 2 años para poder definir la mejor opción para implementar la función de componentes, dando los siguientes resultados:

En el primer caso se realiza la transformación de 4 componentes por año, para realizar un pronóstico a 5 años dando un total de 20 componentes a pronosticar para este primer caso.

	<i>Año 1</i>	<i>Año 2</i>	<i>Año 3</i>	<i>Año 4</i>	<i>Año 5</i>
<i>Componente 1</i>	17.481026	17.310352	17.527275	17.405819	17.544342
<i>Componente 2</i>	24.333435	24.487503	24.304537	24.36825	24.384491
<i>Componente 3</i>	25.190073	25.01916	25.157293	25.00327	25.017275
<i>Componente 4</i>	18.50463	18.267946	18.443893	18.38271	18.399513

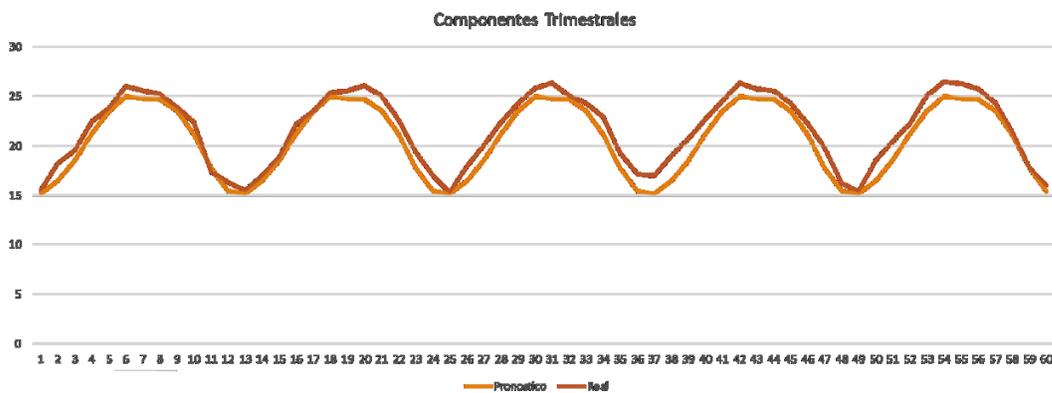
Tabla 8 Resultados CNN (Componentes trimestrales)

Después, se aplicando la fórmula de estimaciones mensuales se obtiene:

	Año 1	Año 2	Año 3	Año 4	Año 5
Enero	15.1997458	15.1982617	15.2001318	15.1990937	15.2002676
Febrero	16.4577283	16.4562442	16.4581142	16.4570761	16.45825
Marzo	18.5174651	18.515981	18.517851	18.516813	18.5179869
Abril	21.2928372	21.2941769	21.2925996	21.2931441	21.2932818
Mayo	23.492574	23.4939137	23.4923364	23.492881	23.4930186
Junio	25.0045915	25.0059313	25.004354	25.0048985	25.0050362
Julio	24.8078077	24.8063215	24.8075123	24.8061958	24.8063145
Agosto	24.7116673	24.7101811	24.7113719	24.7100555	24.7101742
Septiembre	23.6172813	23.6157951	23.6169859	23.6156695	23.6157882
Octubre	21.1401283	21.1380702	21.139587	21.1390641	21.1392065
Noviembre	17.7639003	17.7618421	17.7633589	17.762836	17.7629784
Diciembre	15.4385494	15.4364913	15.4380081	15.4374851	15.4376275

Tabla 9 Estimaciones mensuales (Componentes trimestrales)

Donde nos otorga la siguiente gráfica con el siguiente MAPE:



MAPE: 4.98%

Figura 9 Grafica Resultados componentes trimestrales

En el segundo caso se realiza la transformación de 3 componentes por año, para realizar un pronóstico a 5 años dando un total de 15 componentes a pronosticar para este segundo caso.

	Año 1	Año 2	Año 3	Año 4	Año 5
Componente 1	18.618462	18.406462	18.614178	18.336828	18.935766
Componente 2	25.710564	25.330069	25.354866	25.289557	25.688385
Componente 3	20.385908	20.111362	20.17422	20.418993	20.449657

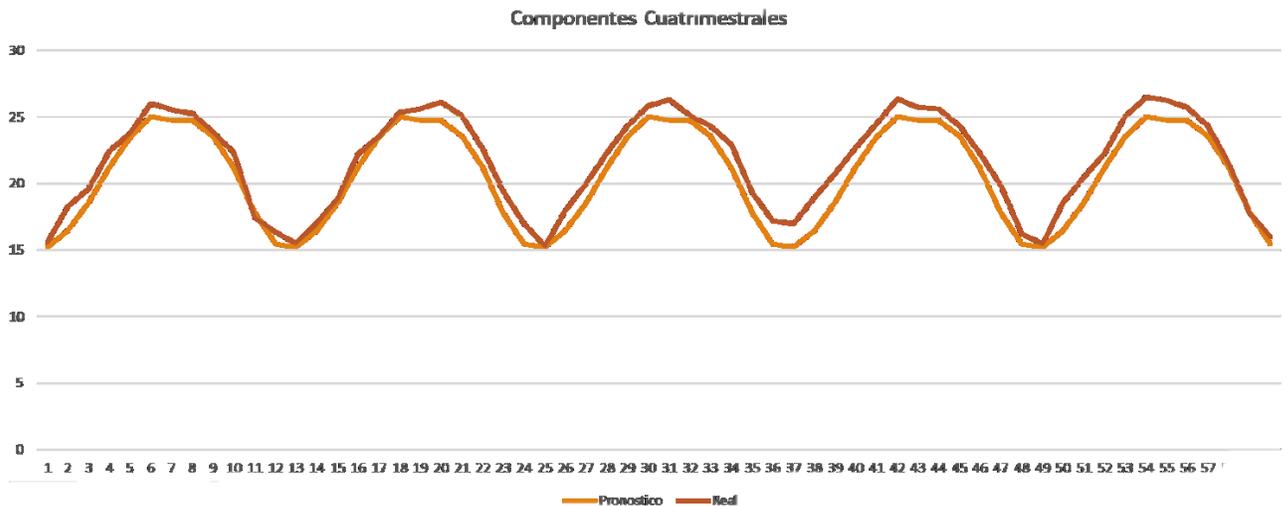
Tabla 10 Resultados CNN (Componentes Cuatrimestrales)

Después, se aplicando la fórmula de estimaciones mensuales se obtiene:

	Año 1	Año 2	Año 3	Año 4	Año 5
<i>Enero</i>	15.2097234	15.2078799	15.2096705	15.2073	15.2123758
<i>Febrero</i>	16.4677058	16.4658623	16.467653	16.4652825	16.4703582
<i>Marzo</i>	18.5274426	18.5255992	18.5273898	18.5250193	18.5300951
<i>Abril</i>	21.2427058	21.2408623	21.242653	21.2402825	21.2453582
<i>Mayo</i>	23.5046541	23.5013454	23.5015592	23.501001	23.5043809
<i>Junio</i>	25.0166716	25.013363	25.0135767	25.0130185	25.0163984
<i>Julio</i>	24.8123734	24.8090647	24.8092785	24.8087203	24.8121002
<i>Agosto</i>	24.716233	24.7129244	24.7131381	24.7125799	24.7159598
<i>Septiembre</i>	23.5751395	23.5727522	23.5732941	23.5753861	23.575646
<i>Octubre</i>	21.1566308	21.1542434	21.1547853	21.1568774	21.1571372
<i>Noviembre</i>	17.7804027	17.7780153	17.7785572	17.7806493	17.7809092
<i>Diciembre</i>	15.4550518	15.4526645	15.4532063	15.4552984	15.4555583

Tabla 11 Estimaciones mensuales (Componentes cuatrimestrales)

Donde nos otorga la siguiente gráfica con el siguiente MAPE:



MAPE: 4.97%

Figura 10 Grafica Resultados componentes cuatrimestrales

En el tercer caso se realiza la transformación de 2 componentes por año, para realizar un pronóstico a 5 años dando un total de 10 componentes a pronosticar para este tercer caso.

	Año 1	Año 2	Año 3	Año 4	Año 5
Componente 1	21.15843	21.46634	21.163715	21.392962	21.672354
Componente 2	21.250443	21.187479	21.38762	21.597845	21.381676

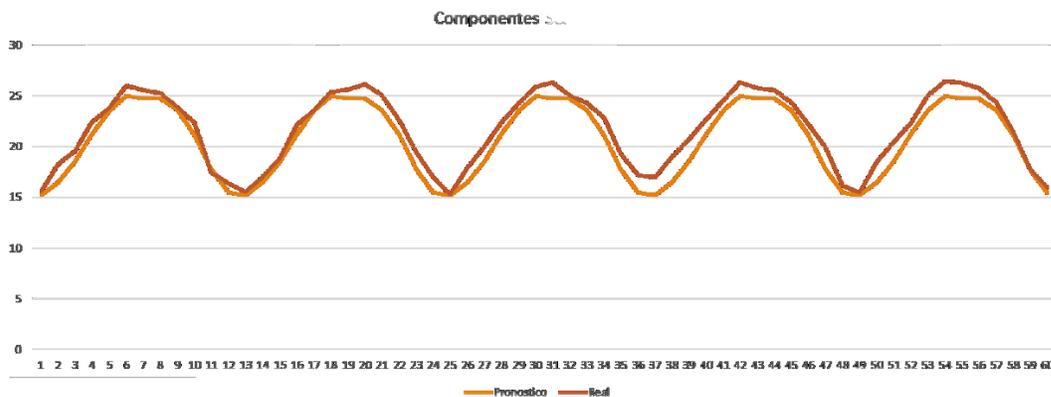
Tabla 12 Resultados CNN (Componentes trimestrales)

Después, se aplicando la fórmula de estimaciones mensuales se obtiene:

	Año 1	Año 2	Año 3	Año 4	Año 5
Enero	21.15843	21.46634	21.163715	21.392962	21.672354
Febrero	19.11084	19.3889523	19.1156135	19.3226754	19.5750294
Marzo	21.15843	21.46634	21.163715	21.392962	21.672354
Abril	20.4759	20.7738774	20.4810145	20.7028665	20.9732458
Mayo	21.15843	21.46634	21.163715	21.392962	21.672354
Junio	20.4759	20.7738774	20.4810145	20.7028665	20.9732458
Julio	21.250443	21.187479	21.38762	21.597845	21.381676
Agosto	21.250443	21.187479	21.38762	21.597845	21.381676
Septiembre	20.5649448	20.5040119	20.6976968	20.9011403	20.6919445
Octubre	21.250443	21.187479	21.38762	21.597845	21.381676
Noviembre	20.5649448	20.5040119	20.6976968	20.9011403	20.6919445
Diciembre	21.250443	21.187479	21.38762	21.597845	21.381676

Tabla 13 Estimaciones mensuales (Componentes semestrales)

Donde nos otorga la siguiente gráfica con el siguiente MAPE:



MAPE:4.98%

Figura 11 Grafica Resultados componentes Semestrales

Al tener identificado el mejor sistema de componentes, se procede a generar el pronóstico de 20 años.

Se realizó el pronóstico a la serie de tiempo, de los cuales se tomaron 80 años (del año 1901 al 1981) para el entrenamiento de la red neuronal, y para la validación se utilizaron 20 años (del año 1981 al 2001), y finalmente, para la etapa de prueba se utilizaron los datos de los años 2001 al 2021.

Serie de tiempo (1901-2021)		
Entrenamiento 1901-1981	Validación 1981-2001	Prueba 2001-2021

Tabla 14 Serie de tiempo utilizada en validación y prueba

Para la etapa de validación, al utilizar la red neuronal, con 4 componentes para pronosticar 20 años, nos otorga la siguiente gráfica de resultados:

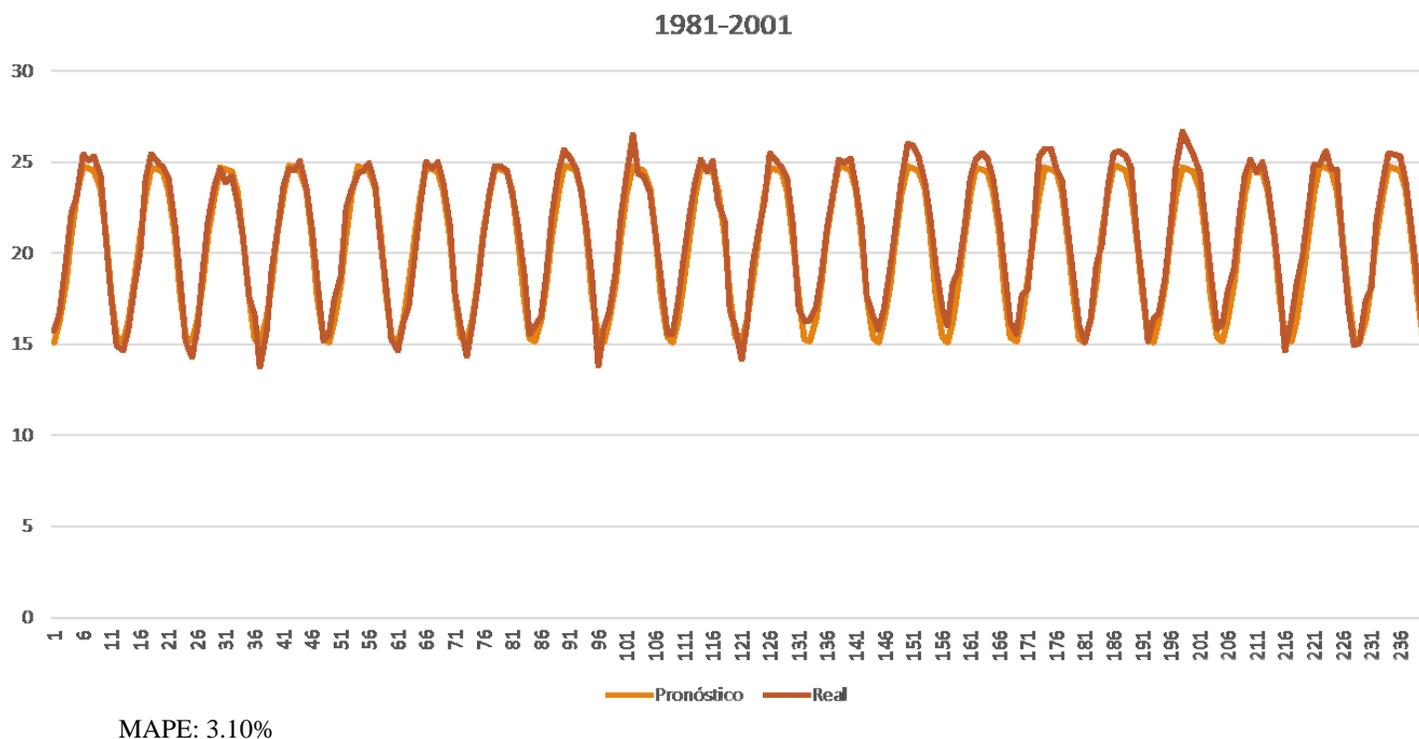


Figura 12 Resultados validación 20 años

Se realizó el ajuste de residuales utilizando el pronóstico de residuales con suavizamiento exponencial simple.

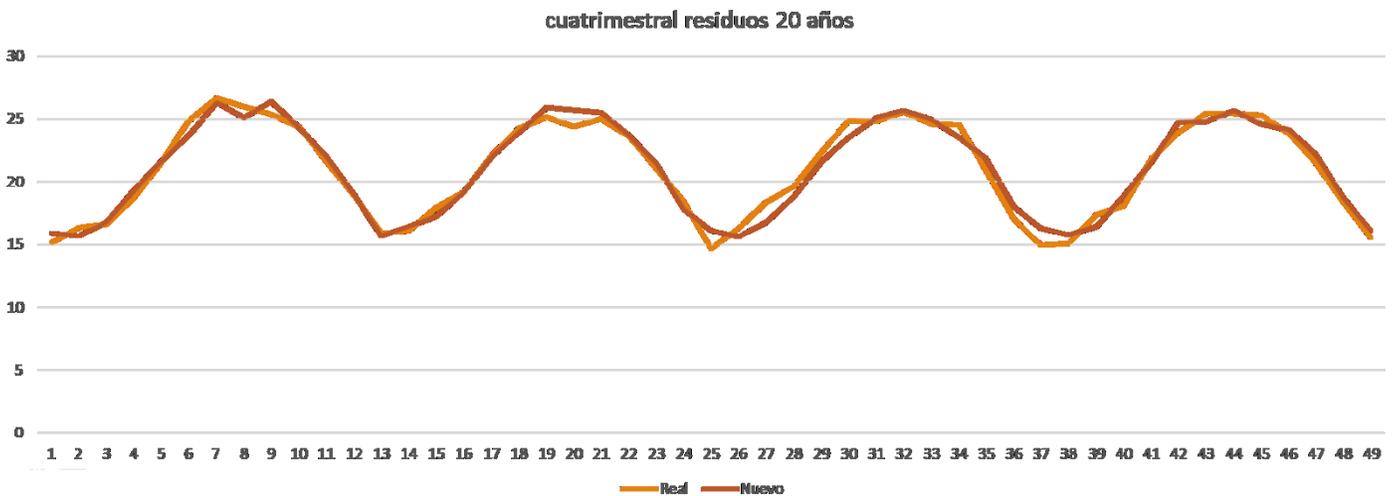
$$F_t = \underbrace{F_{t-1}}_{\text{Pronóstico del período anterior}} + \alpha \underbrace{(A_{t-1} - F_{t-1})}_{\text{Error del pronóstico del período anterior}}$$

Este pronóstico, se aplica a los datos otorgados por la etapa de validación, donde se toman los residuales de esta etapa para generar el entrenamiento y la validación para este pronóstico.

Serie de tiempo (1901-2021)		
Entrenamiento 1901-1981	Validación 1981-2001	Prueba 2001-2021
	Entrenamiento (Residuales)	Validación (Residuales)

Tabla 15 explicación de la utilidad de residuales en la validación

Al ajustar los residuales obtenidos de este pronóstico a los resultados pronosticados de la serie de temperatura, obtenemos la siguiente gráfica con el nuevo MAPE:



MAPE: 3.01%

Figura 13 Resultados validación 20 años después de residuales

Esta etapa de pronóstico de residuales, nos permite generar los residuales pronosticados para la etapa de prueba de la red neuronal.

Los residuales pronosticados bajo el método de suavizamiento exponencial, obtenemos los siguientes valores, representados en la siguiente gráfica:

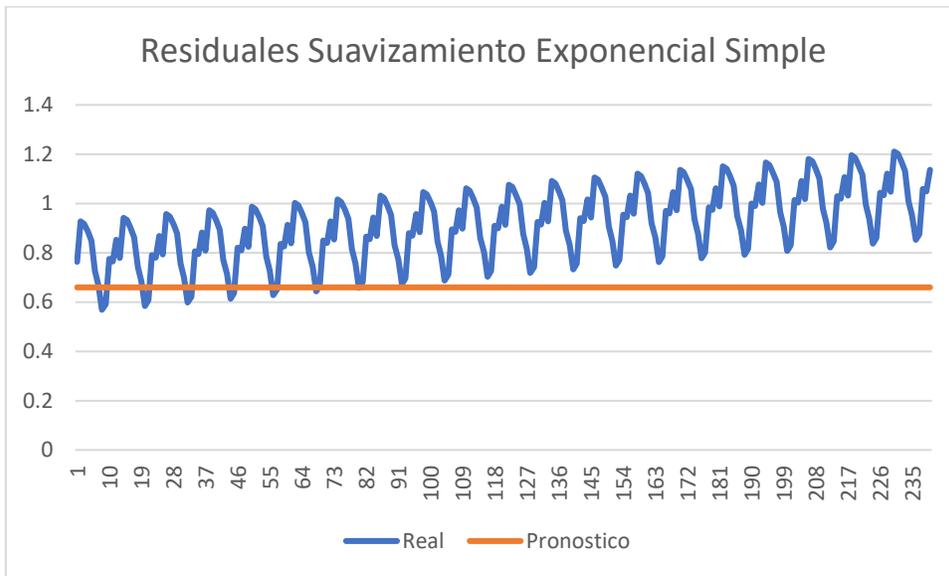


Figura 14 Pronóstico de residuales utilizando Suavizamiento Exponencial Simple

Con un MAPE sobre los valores residuales reales de 18.45%

En la etapa de prueba, se realizó el pronóstico utilizando los datos de temperatura obtenidos por la etapa de validación, dando la siguiente gráfica como resultado:

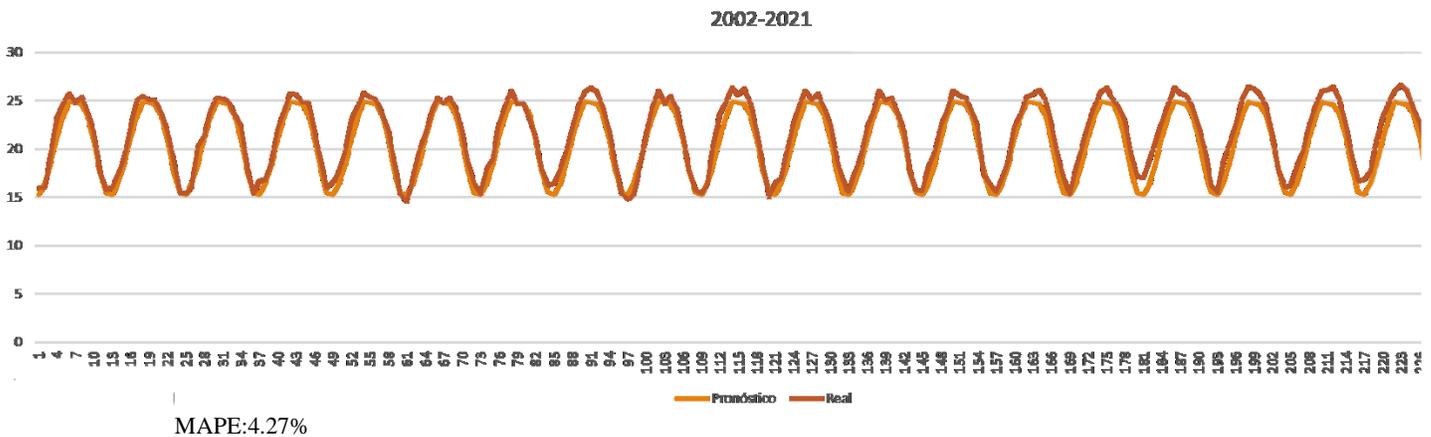


Figura 15 Resultados de pronóstico en etapa de prueba a 20 años

Al aplicar los residuales pronosticados por suavizamiento exponencial simple a los datos de temperatura pronosticados obtenemos los siguientes resultados:

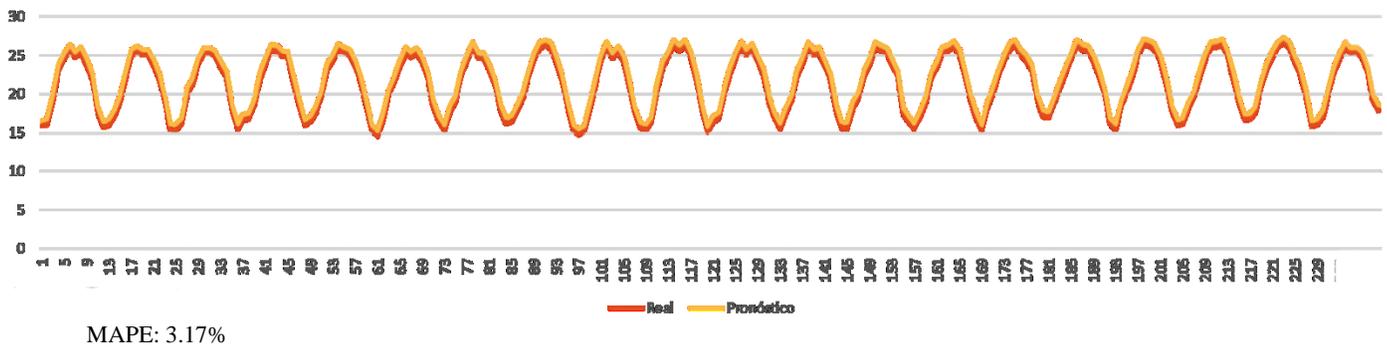


Figura 16 Resultados del pronóstico en la etapa de prueba a 20 años después de residuales por suavizamiento exponencial simple.

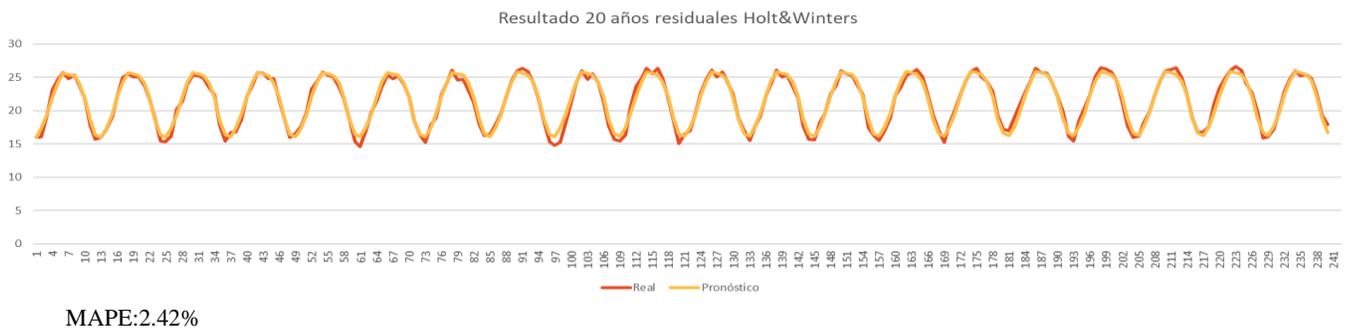


Figura 17 Resultados del pronóstico en la etapa de prueba a 20 años después de residuales por Holt&Winters.

Al aplicar los residuales pronosticados por el método Holt&Winters a los datos de temperatura pronosticados obtenemos los siguientes resultados:

En este último paso, obtenemos el resultado final al aplicar los métodos de pronóstico propuestos, obteniendo un buen resultado en base al porcentaje del MAPE obtenido, demostrando la efectividad de estos métodos de pronóstico como la Red Neuronal, además de demostrar que el uso de residuales tanto por suavizamiento exponencial simple como por Holt&Winters mejora firmemente el resultado pronosticado, siendo este último el que mejor resultados demuestra.

4.2 Usando SVR con algoritmo genético

Para utilizar un SVR se aplicó un algoritmo Genético para sintonizar los parámetros de costo, kernel y epsilon.

Se utiliza una serie de tiempo de temperatura 5 años para generar resultados a dos años.

El programa funciona de la siguiente manera:

Se generan aleatoriamente diferentes parámetros otorgados por el genético y se ejecuta el algoritmo de SVR, el cual arroja resultados en temperatura mensual para los dos años mencionados, los cuales se comparan para generar un valor MAPE.

El proceso se repite 30 veces y de estas 30 veces, se selecciona el valor de MAPE más bajo.

Después de ejecutar el programa 60 veces, se encontraron los parámetros en los cuales se dio el menor MAPE encontrado:

Resultados				Resultados			
kernel	Costo	Epsilon	MAPE	kernel	Costo	Epsilon	MAPE
'linear'	8.6	0.2	2.37058123	'linear'	10	0.19	2.48227269
'linear'	2.8	0.21	2.4313415	'linear'	1.36	0.21	2.42005631
'linear'	4.8	0.2	2.36523708	'linear'	8.6	0.055	3.03382436
'linear'	8.2	0.19	2.47848575	'linear'	1.7	0.045	2.99344482
'poly'	8	0.0034	2.9755515	'linear'	4.5	0.21	2.44466428
'poly'	8.9	0.0026	3.03138007	'linear'	2.85	0.21	2.43173334
'linear'	4.3	0.19	2.44508456	'rbf'	7.6	0.02	3.00214061
'linear'	1.85	0.17	2.80640678	'linear'	7.4	0.18	2.71506972
'linear'	5	0.17	2.89554356	'linear'	8.3	0.19	2.47976878
'linear'	8.5	0.2	2.3683565	'linear'	3.35	0.19	2.45472911
'linear'	5.5	0.2	2.3588064	'linear'	1.55	0.18	2.6065972
'linear'	5	0.2	2.36194951	'linear'	3.6	0.2	2.39313691
'linear'	8	0.18	2.77914314	'linear'	4.6	0.055	3.02710379
'poly'	7.5	0.006	2.95234248	'poly'	7.8	0.01	3.07032808
'linear'	4.1	0.2	2.37896655	'linear'	4.1	0.18	2.59089487
'linear'	7.3	0.19	2.44683219	'linear'	1.5	0.17	2.90637831
'poly'	7.9	0.031	3.07507426	'poly'	9	0.0033	3.02491378
'linear'	2.5	0.18	2.59946386	'linear'	2.65	0.19	2.4620351
'poly'	10	0.029	3.03636466	'linear'	1.9	0.045	2.9850111

Capítulo 4. Resultados

'linear'	2.4	0.19	2.46465155	'poly'	7.7	0.0075	2.94941669
'linear'	7.9	0.2	2.37150135	'linear'	1.31	0.2	2.52793347
'linear'	4.9	0.2	2.36511761	'linear'	4.1	0.2	2.37896655
'linear'	3.25	0.2	2.39773009	'linear'	2.55	0.21	2.42938226
'linear'	7.9	0.21	2.48006948	'linear'	3.3	0.2	2.39844773
'linear'	2.85	0.17	2.81744106	'linear'	7.5	0.2	2.37177289
'linear'	5	0.17	2.89554356	'linear'	3.9	0.19	2.44933035
'linear'	1.25	0.21	2.674037	'linear'	1.37	0.21	2.42013468
'linear'	2.6	0.21	2.42977411	'linear'	2.2	0.21	2.42663934
'linear'	10	0.19	2.48227269	'poly'	7.1	0.0075	2.94431569
'linear'	1.36	0.21	2.42005631	'linear'	5.5	0.18	2.64372267

Tabla 16 Resultados de sintonización de SVR mediante Algoritmo genético

5 Conclusiones

- Después de analizar los resultados obtenidos para cada variante de componentes, se ha determinado que el uso de componentes cuatrimestrales arroja mejores resultados.
- El uso de residuales mejora la precisión de los resultados otorgados por una CNN.
- La sintonización de parámetros en el SVR mediante algoritmos genéticos ayuda a obtener una precisión muy acertada compitiendo con las entregadas por el estado del arte
- La predicción de los valores de temperatura mediante técnicas de aprendizaje automático nos permite obtener un horizonte de pronóstico más extenso.
- Ambas técnicas empleadas otorgan resultados competitivos a los entregados por el estado del arte, dando menos de un 3% de error para ambos casos.

Bibliografía

En este capítulo final se expresan las referencias de los autores cuyos trabajos y estudios sirvieron de apoyo para realizar el proyecto, dando las respectivas referencias enumeradas en cada capítulo anterior a este.

- [1] Mas Machuca, M., Sainz, M., & Martínez Costa, C. (2014). A review of forecasting models for new products. *Intangible Capital*, 10(1),1-25.[fecha de Consulta 18 de Noviembre de 2022]. ISSN: 2014-3214. Recuperado de: <https://www.redalyc.org/articulo.oa?id=54930453001>
- [2] Robert R. Andrawis, Amir F. Atiya, Hisham El-Shishiny, Forecast combinations of computational intelligence and linear models for the NN5 time series forecasting competition, 2011, <https://doi.org/10.1016/j.ijforecast.2010.09.005>
- [3] Prado, Francisco & Minutolo, Marcel & Kristjanpoller, Werner. (2020). Forecasting Based on an Ensemble Autoregressive Moving Average - Adaptive Neuro - Fuzzy Inference System – Neural Network - Genetic Algorithm Framework. *Energy*. 197. 117159. [10.1016/j.energy.2020.117159](https://doi.org/10.1016/j.energy.2020.117159)
- [4] Saad Mowafy, M.A.A. and Elaraby Mohamed Shallan, W.M. (2021), "Improving the classification accuracy using hybrid techniques", *Review of Economics and Political Science*, Vol. 6 No. 3, pp. 223-234. <https://doi.org/10.1108/REPS-10-2020-0161>
- [5] Aaron M. McCright, Riley E. Dunlap, Challenging Global Warming as a Social Problem: An Analysis of the Conservative Movement's Counter-claims, *Social Problems*, Volume 47, Issue 4, 1 November 2000, Pages 499–522, <https://doi.org/10.2307/3097132>
- [6] Scher, S., & Messori, G. (2019). How global warming changes the difficulty of synoptic weather forecasting. *Geophysical Research Letters*, 46, 2931– 2939. <https://doi.org/10.1029/2018GL081856>
- [7] Sean J. Taylor & Benjamin Letham (2018) Forecasting at Scale, *The American Statistician*, 72:1, 37-45, <https://doi.org/10.1080/00031305.2017.1380080>
- [8] Teuvo Kohonen(1988), An introduction to neural computing, *Neural Networks*, 1, 3-16, [https://doi.org/10.1016/0893-6080\(88\)90020-2](https://doi.org/10.1016/0893-6080(88)90020-2)

- [9] Matich, D. J. (2001) Redes Neuronales: Conceptos Básicos y Aplicaciones. [Neural Networks: Basic Concepts and Applications.] Universidad Tecnológica Nacional—Facultad Regional Rosario, Departamento de Ingeniería Química, Argentina.
- [10] Escalona, Uriel, Arce, Fernando, Zamora, Erik, Azuela, Juan (2019), Fully Convolutional Networks for Automatic Pavement Crack Segmentation, *Computación y Sistemas*, 23, <http://dx.doi.org/10.13053/cys-23-2-3047>
- [11] Dietterich, T.G. (2000). Ensemble Methods in Machine Learning. Multiple Classifier Systems. https://doi.org/10.1007/3-540-45014-9_1
- [12] Kazienko P, Lughofer E, Trawiński B (2013) Hybrid and Ensemble Methods in Machine Learning. *JUCS - Journal of Universal Computer Science* 19(4): 457-461. <https://doi.org/10.3217/jucs-019-04>
- [13] Frausto-Solís, J.; Hernández-González, L.J.; González-Barbosa, J.J.; Sánchez-Hernández, J.P.; Román-Rangel, E. Convolutional Neural Network–Component Transformation (CNN–CT) for Confirmed COVID-19 Cases. *Math. Comput. Appl.* 2021, 26, 29. <https://doi.org/10.3390/mca26020029>
- [14] Smola, A.J., Schölkopf, B. A tutorial on support vector regression. *Statistics and Computing* 14, 199–222 (2004). <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- [15] Toby Segaran. 2007. Programming collective intelligence (First. ed.). O'Reilly.
- [16] Hsu, Chih-wei & Chang, Chih-chung & Lin, Chih-Jen. (2003). A Practical Guide to Support Vector Classification Chih-Wei Hsu, Chih-Chung Chang, and Chih-Jen Lin.
- [17] Cortes, C., Vapnik, V. Support-vector networks. *Mach Learn* 20, 273–297 (1995). <https://doi.org/10.1007/BF00994018>
- [18] Melanie Mitchell. 1998. An Introduction to Genetic Algorithms. MIT Press, Cambridge, MA, USA.
- [19] Yunjie Liu, Evan Racah, Prabhat, Joaquin Correa, Amir Khosrowshahi, David Lavers, Kenneth Kunkel, Michael Wehner, William Collins (2016), Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets, arXiv, <https://doi.org/10.48550/arXiv.1605.01156>
- [20] Hubig, N., Fengler, P., Züfle, A., Yang, R., Günemann, S. (2017). Detection and Prediction of Natural Hazards Using Large-Scale Environmental Data. In: , et al. *Advances*

in Spatial and Temporal Databases. SSTD 2017. Lecture Notes in Computer Science(), vol 10411. Springer, Cham. https://doi.org/10.1007/978-3-319-64367-0_16

[21] M. S. Hossain and H. Mahmood, "Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast," in IEEE Access, vol. 8, pp. 172524-172533, 2020, doi: 10.1109/ACCESS.2020.3024901.

[22] A. G. Salman, B. Kanigoro and Y. Heryadi, "Weather forecasting using deep learning techniques," 2015 International Conference on Advanced Computer Science and Information Systems (ICACISIS), 2015, pp. 281-285, doi: 10.1109/ICACISIS.2015.7415154.