



**ESCUELA SUPERIOR POLITÉCNICA AGROPECUARIA DE MANABÍ
MANUEL FÉLIX LÓPEZ**

CARRERA DE INFORMÁTICA

**TRABAJO DE TITULACIÓN PREVIA LA OBTENCIÓN DEL TÍTULO DE
INGENIERO EN INFORMÁTICA**

MODALIDAD: SISTEMATIZACIÓN DE EXPERIENCIAS

TEMA:

MODELO DE PREDICCIÓN CLIMÁTICA

AUTORES:

MARJORIE STEFANY KUFFÓ ZAMBRANO

JUAN JOSÉ PINARGOTE ZAMBRANO

TUTOR:


ING. JAVIER HERNÁN LÓPEZ ZAMBRANO, MG. TI.

CALCETA, OCTUBRE 2021

DERECHOS DE AUTORÍA

Yo Marjorie Stefany Kuffó Zambrano, con cédula de ciudadanía 131391902-7; y Juan José Pinargote Zambrano, con cédula de ciudadanía 131522880-7; declaramos bajo juramento que el trabajo de Titulación titulado: **MODELO DE PREDICCIÓN CLIMÁTICA** es de nuestra autoría, que no ha sido previamente presentado para ningún grado o calificación profesional, y que hemos consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración, concedemos a favor de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos, conservando a nuestro favor todos los derechos patrimoniales de autor sobre la obra, en conformidad con el Artículo 114 del Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación.



.....
MARJORIE S. KUFFÓ ZAMBRANO



.....
JUAN J. PINARGOTE ZAMBRANO

CERTIFICACIÓN DE TUTOR

Javier Hernán López Zambrano certifica haber tutelado el trabajo de titulación **MODELO DE PREDICCIÓN CLIMÁTICA**, que ha sido desarrollado por Marjorie Stefany Kuffó Zambrano y Juan José Pinargote Zambrano, previa la obtención del título de Ingeniero en Informática, de acuerdo al **REGLAMENTO DE LA UNIDAD DE TITULACIÓN ESPECIAL DE PROGRAMAS DE GRADO** de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López.



Firmado digitalmente
por JAVIER HERNAN
LOPEZ ZAMBRANO

.....
ING. JAVIER H. LÓPEZ ZAMBRANO. MG. TI

APROBACIÓN DEL TRIBUNAL

Los suscritos integrantes del tribunal correspondiente, declaran que han **APROBADO** el trabajo de titulación **MODELO DE PREDICCIÓN CLIMÁTICA**, que ha sido propuesto, desarrollado y sustentado por **Marjorie Stefany Kuffó Zambrano y Juan José Pinargote Zambrano**, previa la obtención del título de Ingeniero en Informática, de acuerdo al **REGLAMENTO DE LA UNIDAD DE TITULACIÓN ESPECIAL DE PROGRAMAS DE GRADO** de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López.



ANGEL ALBERTO
VELEZ MERO
Firmado digitalmente.
avelez@espam.edu.ec



Firmado electrónicamente por:
**ALFONSO
TOMAS LOOR**

.....
ING. ÁNGEL A. VÉLEZ MERO, MG

MIEMBRO

.....
ING. ALFONSO T. LOOR VERA, MG

MIEMBRO



Firmado electrónicamente por:
**LUIS CRISTOBAL
CEDENO VALAREZO**

.....
ING. LUIS C. CEDEÑO VALAREZO, MG

PRESIDENTE

AGRADECIMIENTO

A la Escuela Superior Politécnica Agropecuaria de Manabí–Manuel Félix López por su trabajo arduo en la formación de profesionales, lo cual, nos ofreció la oportunidad de formarnos como profesionales con una educación de calidad,

Así mismo, expresamos nuestro agradecimiento a la Carrera de Informática por sus enseñanzas durante todo el proceso formativo dentro de sus aulas y a sus docentes que, con su labor y compromiso, nos guiaron con conocimientos, consejos y pautas para alcanzar el éxito dentro de la carrera,

A nuestro tutor de tesis Ing. Javier Hernán López Zambrano, MG. TI. quien con su experiencia, conocimiento y motivación nos orientó en el transcurso de la investigación,

A nuestros padres por habernos apoyado incondicionalmente, pese a las adversidades e inconvenientes que se presentaron.

LOS AUTORES

DEDICATORIA

A Dios por haberme dado la fortaleza y la fuerza necesaria para cumplir con cada una de mis metas, objetivos, propósitos y en especial mi formación profesional.

A mis padres Estalin y Yesenia por apoyarme tanto en lo moral como en lo financiero, por brindarme la confianza necesaria y permitirme cumplir cada uno de mis sueños.

A mis familiares por su voz de aliento e inspirarme a convertirme en una profesional de éxito, con ética y principios, capaz de superar cada una de los obstáculos que se presenten a lo largo de mi profesión.

MARJORIE S. KUFFÓ ZAMBRANO

DEDICATORIA

Dedico este trabajo principalmente a Dios, por permitirme haber llegado hasta este momento tan importante en mi vida, y por haberme escuchado en mis oraciones para poder alcanzar la meta de ser un profesional en el área informática.

A mi madre, Yenny Monserrate Zambrano por ser el pilar más importante y por demostrarme siempre su amor y apoyo incondicional en los momentos más difíciles de mi vida, enseñándome que nunca debo perder la fe para poder alcanzar mis sueños.

A mi padre, Juan Bosco Pinargote Zambrano por su apoyo moral y económico durante mi proceso de formación, brindándome sus consejos y experiencias para no llevar un mal camino tanto como persona y profesional.

A mis amigos y demás familiares, que de una u otra forma me apoyaron en el transcurso de poder alcanzar mi sueño de ser profesional.

JUAN J. PINARGOTE ZAMBRANO

CONTENIDO GENERAL

DERECHOS DE AUTORÍA	ii
CERTIFICACIÓN DE TUTOR	iii
APROBACIÓN DEL TRIBUNAL	iv
AGRADECIMIENTO	v
DEDICATORIA	vi
DEDICATORIA	vii
RESUMEN	xiv
PALABRAS CLAVE	xiv
ABSTRACT	xv
KEY WORDS	xv
CAPÍTULO I. ANTECEDENTES	1
1.1. DESCRIPCIÓN DE LA INSTITUCIÓN	1
1.2. DESCRIPCIÓN DE LA INTERVENCIÓN	3
1.3. OBJETIVOS	5
1.3.1. OBJETIVO GENERAL	5
1.3.2. OBJETIVOS ESPECÍFICOS	5
CAPÍTULO II. DESARROLLO METODOLÓGICO DE LA INTERVENCIÓN	6
2.1. REVISIÓN DEL ESTADO DEL ARTE	6
2.1.1. REVISIÓN SISTEMÁTICA	6
2.1.1.1. ELABORACIÓN DE LA PREGUNTA	8
2.1.1.2. ESTABLECIMIENTO DE LOS CRITERIOS DE INCLUSIÓN Y BÚSQUEDA SISTEMÁTICA	8
2.1.1.3. SELECCIÓN DE LOS ESTUDIOS	9
2.1.1.4. EXTRACCIÓN DE LOS DATOS	9
2.2. DETERMINACIÓN DE ALGORITMOS PARA LA CREACIÓN DEL MODELO	10
2.2.1. RESUMEN Y DIFUSIÓN DE LOS RESULTADOS	10
2.3. OBTENCIÓN DEL CONJUNTO DE DATOS	10
2.4. CONSTRUCCIÓN DEL MODELO	12
CAPÍTULO III. DESCRIPCIÓN DE LA EXPERIENCIA	14
3.1. REVISIÓN DEL ESTADO DEL ARTE	14
3.1.1. ELABORACIÓN DE LA PREGUNTA	14

3.1.2. ESTABLECIMIENTO DE LOS CRITERIOS DE INCLUSIÓN Y BÚSQUEDA SISTEMÁTICA	14
3.1.3. REVISIÓN Y SELECCIÓN DE ESTUDIOS.....	15
3.1.4. EXTRACCIÓN DE DATOS.....	16
3.2. DETERMINACIÓN DE ALGORITMOS PARA LA CREACIÓN DEL MODELO	17
3.2.1. RESUMEN Y DIFUSIÓN DE LOS RESULTADOS DE LA REVISIÓN SISTEMÁTICA	17
3.2.1.1. ¿CUÁLES SON LOS MODELOS COMPUTACIONALES MÁS EMPLEADOS EN LAS PREDICCIONES CLIMÁTICAS?	17
3.2.1.2. ¿CUÁLES SON LOS ALGORITMOS QUE EMPLEAN ESTOS MODELOS COMPUTACIONALES EN LAS PREDICCIONES CLIMÁTICAS?.....	18
3.2.1.3. ¿CUÁL FUE EL MODELO Y ALGORITMO CON MEJOR PORCENTAJE DE EFECTIVIDAD EN LAS PREDICCIONES CLIMÁTICAS	20
3.2.1.4. ¿CUÁLES FUERON LAS HERRAMIENTAS EMPLEADAS PARA LA CONSTRUCCIÓN DEL MODELO Y ALGORITMO?	21
3.2.1.5. MÉTRICAS.....	22
3.2.1.6. VARIABLES CLIMÁTICAS	22
3.3. OBTENCIÓN DEL CONJUNTO DE DATOS	23
3.4. CONSTRUCCIÓN DEL MODELO	26
CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES.....	39
4.1. CONCLUSIONES	39
4.2. RECOMENDACIONES	40
BIBLIOGRAFÍA.....	41
ANEXOS.....	45

CONTENIDO DE TABLAS

Tabla 2.1. Fases de las Revisiones Sistemáticas	7
Tabla 2.2. Interpretación del coeficiente de correlación.....	12
Tabla 3.1. Formulación de las Preguntas de Investigación	14
Tabla 3.2. Criterios de inclusión y búsqueda sistemáticas	15
Tabla 3.4. Variables existentes en los datasets	23
Tabla 3.5. Librerías utilizadas para el desarrollo del modelo	26
Tabla 3.6. Error Cuadrático Medio obtenido durante el entrenamiento con 150 epochs	29
Tabla 3.7. Variables adicionales empleadas en el entrenamiento	30
Tabla 3.8. Precisión del modelo con los datos de la Estación Meteorológica de la ESPAM - MFL	35
Tabla 3.9. Precisión del modelo con los datos del sitio web Power Data Access Viewer	36
Tabla 3.10. Pronóstico del clima con los datos de la estación meteorológica de la ESPAM – MFL para los próximos 15 días	37
Tabla 3.11. Pronóstico del clima con los datos del sitio web Power Data Access Viewer para los próximos 15 días.....	37

CONTENIDO DE GRÁFICOS

Gráfico 3.1. Modelos Computacionales empleados para las predicciones relacionadas al clima.....	17
Gráfico 3.2. Porcentajes de Efectividad de la Red Neuronal Recurrente con el algoritmo LSTM.....	18
Gráfico 3.3. Porcentajes de Efectividad de la Red Neuronal Feedforward con el algoritmo de Backpropagation.....	18
Gráfico 3.4. Porcentajes de Efectividad de la Red Neuronal Multicapa con el algoritmo de Backpropagation.....	19
Gráfico 3.5. Porcentajes de Efectividad del modelo ARIMA empleando los algoritmos de SVM y Naive Bayes.	19
Gráfico 3.6. Porcentajes de Efectividad de Efectividad del modelo ARIMA empleando el algoritmo Autoregressive Integrated Moving Average	20
Gráfico 3.7. Lenguajes de Programación empleados en la elaboración de modelos computacionales.....	21
Gráfico 3.8. Métrica empleada para la efectividad de los modelos computacionales	22
Gráfico 3.9. Variables más utilizadas en los artículos científicos	22
Gráfico 3.10. Valores Reales y Predichos de la Humedad Relativa.....	30
Gráfico 3.11. Valores Reales y Predichos de la Temperatura Máxima	31
Gráfico 3.12. Valores Reales y Predichos de la Temperatura Mínima	31
Gráfico 3.13. Valores Reales y Predichos de la Precipitación	31
Gráfico 3.14. Valores Reales y Predichos de la Velocidad del Viento.....	32
Gráfico 3.15. Valores Reales y Predichos de la Humedad Relativa.....	32
Gráfico 3.16. Valores Reales y Predichos de la Temperatura Máxima	33
Gráfico 3.17. Valores Reales y Predichos de la Temperatura Mínima	33
Gráfico 3.18. Valores Reales y Predichos de la Precipitación	33
Gráfico 3.19. Valores Reales y Predichos de la Velocidad del Viento.....	34
Gráfico 3.20. Valores Reales y Predichos de la Temperatura Ambiente.....	34
Gráfico 3.21. Valores Reales y Predichos de la Evaporación	35

CONTENIDO DE FIGURAS

Figura 2.1. Flujo de ejecución para la construcción del modelo	13
Figura 3.1. Proceso de selección de los artículos	16
Figura 3.2. Exploración de los Datos	23
Figura 3.3 Matriz de correlación de Pearson - Set_ESPAM.....	24
Figura 3.4. Matriz de correlación de Pearson - Set_PowerData.....	25
Figura 3.5. Procesamientos de los datos.....	26
Figura 3.6. Código en Python de la configuración de los parámetros que serán procesados	27
Figura 3.7. Código fuente en Python de la estructura de la red neuronal recurrente – LSTM	28
Figura 3.8. Resumen del entrenamiento de la red neuronal recurrente – LSTM	29
Figura 3.9. Ecuación de exactitud.....	35

CONTENIDO DE ANEXOS

Anexo 1. Datos extraídos de los artículos seleccionados	47
Anexo 2(A). Medidas mensuales de la estación meteorológica de la ESPAM – MFL	54
Anexo 2(B). Informe - Power Data Access Viewer.....	57
Anexo 2(C). Medidas mensuales del visor de acceso de datos	61
Anexo 3(A). Data set de la estación meteorológica de la espam - mfl	64
Anexo 3(B). Data set power data acces viewer	65
Anexo 4(A). Dispersión de los datos con la correlación de pearson – set_espam	66
Anexo 4(B). Dispersión de los datos con la correlación de pearson – set_powerdata	67
Anexo 5(A). Entrenamiento y testeo con la red Neuronal Feedforward	68
Anexo 5(B). Entrenamiento y testeo con la red neuronal Perceptron Multicapa	69
Anexo 6(A). Predicciones de los próximos 15 días con los datos de la estación meteorológica de espam-mfl	70
Anexo 6(B). Predicciones de los próximos 15 días con los datos del sitio web power data acces viewer.....	71

RESUMEN

El presente trabajo de titulación tuvo como objetivo desarrollar un modelo de predicción climática para el pronóstico meteorológico en el Cantón Bolívar, fue necesario emplear técnicas como la revisión bibliográfica, recopilación de datos y análisis. Se resumió la información y resultados de otras investigaciones, con el propósito de estar al tanto con las aportaciones realizadas dentro de los últimos cinco años acerca del objeto de estudio. Luego, empleando un análisis comparativo dentro del estado del arte, se determinó que el modelo más factible para su aplicación dentro del trabajo fue la Red Neuronal Recurrente en conjunto a la estructura del algoritmo de memoria larga a corto plazo o LSTM. Seguidamente, se recopiló información histórica del clima perteneciente a la zona, para el entrenamiento y testeo del modelo se empleó registros de la estación Meteorológica de la ESPAM - MFL y del sitio web meteorológico Power Data Access Viewer (NASA), efectuándose también una exploración de datos y la correlación de Pearson para observar cuán relacionadas están las variables de los dataset, determinando que las mismas poseen comportamientos independientes entre sí. Finalmente, se construyó el modelo utilizando el lenguaje de programación Python en una versión 3.7.5, se definieron 150 epochs para el entrenamiento, obteniéndose mejores resultados en las variables de la humedad, temperatura máxima y la temperatura mínima, teniendo una exactitud entre los valores reales y predichos del 89.27%, 92.00%, y 90.61% con los datos de estación meteorológica y con el segundo dataset consiguieron un 93.75%, 94.54%, y 96.96%.

PALABRAS CLAVE

Modelo de predicción, pronóstico del clima, series de tiempo climáticas, aprendizaje automático

ABSTRACT

The objective of this degree work was to develop a climate prediction model for weather forecasting in Canton Bolivar, it was necessary to use techniques such as the review of the state of the art, data collection and analysis. The information and results of other research were summarized, with the purpose of being up to date with the contributions made within the last five years about the object of study. Then, using a comparative analysis within the state of the art, it was determined that the most feasible model for its application within the work was the Recurrent Neural Network in conjunction with the structure of the long short-term memory or LSTM algorithm. Next, historical climate information pertaining to the area was collected, and for training and testing the model, records from the ESPAM - MFL meteorological station and the meteorological website Power Data Access Viewer (NASA) were used, and a data exploration and Pearson correlation was also performed to observe how related the variables of the datasets are, determining that they have independent behaviors among them. Finally, the model was built using the Python programming language in version 3.7.5, 150 epochs were defined for training, obtaining better results in the variables of humidity, maximum temperature and minimum temperature, with an accuracy between the real and predicted values of 89.27%, 92.00%, and 90.61% with the data from the meteorological station and with the second dataset they obtained 93.75%, 94.54%, and 96.96%.

KEY WORDS

Prediction model, weather forecast, climate time series, machine learning.

CAPÍTULO I. ANTECEDENTES

1.1. DESCRIPCIÓN DE LA INSTITUCIÓN

La Escuela Superior Politécnica Agropecuaria de Manabí "Manuel Félix López", ESPAM MFL, es una universidad pública ecuatoriana y sin fines de lucro ubicada en la ciudad de Calceta, Cantón Bolívar, establecida a través de la Ley 99-25 en el padrón 181 de 30 de abril de 1999 reformativa a la Ley 116 expedida por el Congreso Nacional, publicada de manera oficial el 29 de abril de 1996, Ley No. 95, publicada en el Registro Oficial No. 728, de 19 de septiembre de 2002 y modificada mediante Ley 2006-49 anunciada en el Suplemento Registro Oficial 298 del 23 de junio del 2006 (ESPAM, 2019).

La universidad busca que sus profesionales que egresan de sus aulas con conocimientos para proponer proyectos que adviertan y den propuestas que aminoren los inconvenientes en sus espacios de formación; consecuentemente la misión de la ESPAM MFL es la de “formar profesionales pertinentes con compromiso ético y social desde la calidad de las funciones sustantivas”, y se proyecta en “ser un centro de referencia en la formación de profesionales que contribuyan al desarrollo agropecuario regional (PEDI, 2017).

Entre las funciones sustantivas de la ESPAM MFL se encuentra la docencia, investigación y vinculación y cada una de ellas están ligadas a las carreras pertenecientes a la institución. Después de lo anterior expuesto, mediante la Coordinación General de investigación se encuentra realizando trabajos mancomunados por el aporte de la universidad a la ciencia. La programación principal de la ESPAM MFL, proyecta un subsistema de la investigación para que contribuya al desarrollo de la zona 4, por dichas consideraciones, en la carrera de Computación emerge la creación del grupo de investigación Sistemas Computacionales (SISCOM), para mejorar los procesos investigativos en esta área, y que aportará directamente a la línea de investigación institucional, teniendo como propósito “contribuir al sector agro-productivo y de servicios con soluciones computacionales, que aporten al desarrollo tecnológico y al entorno social” (PEDI, 2017). Este grupo contempla principalmente los siguientes

campos de la ciencia, tales como: el aprendizaje automático y asistido, minería de datos, robótica (Inteligencia artificial), optimización de procesos, sistemas distribuidos, entre otros; mismos que son aplicados para el desarrollo de proyectos. En la actualidad, el grupo de SISCOM en conjunto con los alumnos de la carrera de computación se encuentran realizando proyectos de investigación con la finalidad de contribuir a la ciencia e investigación ante problemáticas emergentes de la zona.

1.2. DESCRIPCIÓN DE LA INTERVENCIÓN

La meteorología es la ciencia que se encarga en estudiar las propiedades de la atmósfera que rodea la Tierra; tales como son las temperaturas, presión, humedad, vientos, lluvias, y otros que constituyen el tiempo atmosférico (Rodríguez, 2018). El poder proporcionar alertas del estado del tiempo y del clima de manera estratégica para el mundo son parte de los objetivos de la meteorología, ya que no solo estudia los fenómenos que se desarrollan en la atmósfera sino también las consecuencias que estos asocian (López, 2017). En un escenario de cambio climático, la adaptación hacia la resiliencia es fundamental para reducir la vulnerabilidad y apuntar al desarrollo de los medios de vida sostenibles, es decir, impulsar la capacidad de adaptación de los cambios severos del clima (Selva, 2016).

Velásquez (2019), señala que, es evidente el cambio climático debido al aumento de los gases de efecto invernadero, observándose un incremento en la temperatura superficial de los océanos como de la atmósfera terrestre. Según Luque et al (2016), sino se aplican nuevas medidas de adaptación ante grandes cambios climáticos implicaría un impacto enorme, lo que dejaría como resultado personas en riesgo tanto económicos, alimenticios u otros. Covarrubias (2017), señala que, la predicción climática brinda alta prioridad para generar conocimientos más precisos acerca de los impactos del cambio climático, identificando a su vez las opciones de adaptación que se pueden poner al alcance de la población rural de escasos recursos. También Rosales et al (2017), destaca que, las predicciones climáticas proporcionan los elementos de apoyo necesarios para tomar decisiones acerca del manejo y planificación de las actividades sensibles al clima.

Las predicciones tradicionalmente se las realiza a partir de métodos estadísticos de frecuencias, que consisten en estudiar eventos pasados para estimar las probabilidades de ocurrencias futuras. Sin embargo, debido a que la variabilidad climática provoca cambios en la media y la varianza en las series de tiempo, los diseños no son confiables sino se aplican métodos que contemplen cambios en las características de los datos a través del tiempo (Olguín, 2020).

Actualmente, uno de los métodos más eficiente es el uso de la inteligencia artificial, que es una realidad en el sector global, siendo aplicada en modo masivo por empresas de punta e innovadoras, a través del desarrollo de aplicaciones predictivas es una de las potencias destacables de esta técnica, ya que facilita la automatización de procesos, la toma de decisiones y el continuo aprendizaje basado en datos (Sandoval, 2018).

Existen investigaciones de modelos predictivos para el pronóstico del clima, por ejemplo, para la predicción del Fenómeno El Niño en Piura, Perú, que consistió en encontrar un patrón de comportamiento de las precipitaciones y luego para predecir el fenómeno alcanzando una tasa de acierto del 98.4% (Carrión et al, 2018). También se destaca la predicción temprana de heladas meteorológicas, que según Riabani et al (2016), las pérdidas en los cultivos son consecuencia de las heladas varían entre 20 a 100% dependiendo de la intensidad y tipo de cultivo, con este modelo se logró obtener una predicción con márgenes de confianza superiores al 90%.

Con todos estos antecedentes mencionados, este trabajo de titulación se vinculó al grupo de investigación "SISCOM" de la carrera de Computación en uno de sus proyectos denominado, "Optimización de riego automatizado en cultivos tropicales basado en sensorización del entorno y predicciones climáticas" que tiene como objetivo "Plantear un sistema de riego automatizado basado en sensorización del entorno y predicción climática, para contribuir a optimizar el riego en cultivos tropicales en la provincia de Manabí. Por ello, los autores tuvieron como finalidad desarrollar un modelo de predicción climática para el pronóstico meteorológico en el cantón Bolívar, empleando técnicas de inteligencia artificial para poder predecir diferentes variables asociadas al clima, los resultados que se obtendrán de la creación del modelo aportará al grupo SISCOM en la etapa predictiva del proyecto de automatización, para que posteriormente sea implementado en la solución de la problemática planteada por el grupo investigativo mencionado.

1.3. OBJETIVOS

1.3.1. OBJETIVO GENERAL

Desarrollar un modelo para el pronóstico meteorológico en el Cantón Bolívar.

1.3.2. OBJETIVOS ESPECÍFICOS

- Revisar el estado del arte sobre modelos de predicción climática.
- Determinar los algoritmos adecuados para la creación del modelo de predicción.
- Obtener los conjuntos de datos (dataset) para el entrenamiento del modelo.
- Construir el modelo de predicción con el/los algoritmos seleccionados.

CAPÍTULO II. DESARROLLO METODOLÓGICO DE LA INTERVENCIÓN

Este trabajo de titulación se desarrolló a través de etapas, donde cada una es correspondiente a la consecución de los objetivos específicos, las cuales fueron definidas como: revisión del estado del arte, determinación de algoritmos para la creación del modelo, obtención del conjunto de datos, y construcción del modelo. Cabe agregar que, en la etapa de revisión del estado del arte, se empleó la metodología de revisión sistemática. De la misma manera, para la determinación de algoritmos se utilizó la última fase de la metodología indicada empleando observaciones y comparativas de los estudios seleccionados. A continuación, se describen las etapas.

2.1. REVISIÓN DEL ESTADO DEL ARTE

En esta etapa se recurrió a la revisión del estado del arte sobre investigaciones documentales de los modelos computacionales empleados para la predicción climática. Guevara (2016), alega que esta técnica permite a los investigadores comprender nuevos sentidos que determinan enfoques y tendencias. En este propósito, los autores pudieron estar en contexto sobre los avances más importantes que se han logrado con respecto al conocimiento del tema, obteniendo información oportuna a considerar con los fines del presente trabajo. Dadas las condiciones que anteceden, se empleó la metodología de Revisión Sistemática con la finalidad de llevar a cabo el proceso del estado del arte de modo ordenado, permitiendo a los autores obtener investigaciones relevantes y precisas acerca del objeto de estudio por medio de sus etapas descritas a continuación:

2.1.1. REVISIÓN SISTEMÁTICA

Esta metodología permite efectuar resúmenes claros y estructurados de la información disponible y está orientada a responder una o varias preguntas referentes a un tema de estudio (Moreno, 2018). Según Fernández et al (2019) se compone de cinco fases descritas en la siguiente tabla, mismas que permiten llevar a cabo un proceso puntual para la recolección de información.

Tabla 2.1. Fases de las Revisiones Sistemáticas

Fases	Resumen
Fase I. Elaboración de la pregunta.	a.- Elaborar la pregunta de investigación en relación con el/los objetivo(s) de la Revisión Sistemática.
Fase II. Establecimiento de los criterios de inclusión, y búsqueda sistemática.	a.- Establecer los criterios de inclusión (i.e. años, idiomas, tipo de evidencia). b.- Elegir las palabras clave adecuadas para la búsqueda de información. c.- Describir todas las fuentes de información en la búsqueda.
Fase III. Revisión y selección de estudios.	a.- Identificar y eliminar estudios que sean duplicados. b.- Revisar títulos y resúmenes, lo pueden realizar dos revisores de manera autónoma utilizando los criterios de inclusión y exclusión considerados.
Fase IV. Extracción de datos.	a.- Se realiza la extracción de los datos de acuerdo con las necesidades de cada R.S. (objetivo, diseño, muestra, contexto, resultados relevantes). b.- Lo pueden realizar un revisor y un segundo la confirma o dos revisores en conjunto extraen los datos y posteriormente los verifican.
Fase V. Análisis y reporte de los resultados.	a.- Los resultados cuantitativos de las investigaciones se estudian de manera numérica, mientras los hallazgos de los estudios cualitativos se examinan utilizando observaciones temáticas.

Fuente: Fernández et al (2019)

Cabe destacar que el proceso de una revisión sistemática no es una simple recolección de investigaciones, además de sistematizar lo que se ha transmitido,

se trata de aportar conocimiento al identificar o configurar tendencia o líneas de investigación, crear categorías que recojan las investigaciones, aportar a la construcción de teorías, llevar a cabo análisis críticos del estado de la investigación y establecer derroteros para futuros estudios (Páramo, 2020). Ahora bien, el proceso realizado de orden sistemático (**tabla 2.1.**) se lo efectuó de la siguiente manera:

2.1.1.1. ELABORACIÓN DE LA PREGUNTA

Toda búsqueda de información parte con la aparición de una o varias incógnitas, de las cuales se determinarán las preguntas clínicas, y dichas preguntas deben ser claras y precisas (Moreno et al, 2018). Es decir, plantear qué incertidumbres se encuentran inmersas dentro del tema a tratar y a medida que el proceso metodológico se vaya efectuando estas deben ser respondidas, lo cual representa una gran ventaja debido a que manifiesta de una vez lo que se desea obtener y conocer, siendo el primer aspecto fundamental y necesario para saber en qué dirección hay que diseñar la investigación y con qué aportes científicos se puede contar.

2.1.1.2. ESTABLECIMIENTO DE LOS CRITERIOS DE INCLUSIÓN Y BÚSQUEDA SISTEMÁTICA

Fernández et al, (2019) alega que en esta etapa se predeterminan los criterios de inclusión alineados con la pregunta de investigación. Estos pueden incluir fechas, idiomas, tipo de fuentes de información (artículos científicos publicados, literatura gris). Según Moreno (2018), la exploración de documentos científicos tiene que ser efectuada en bases de datos electrónicas y de manera manual en revistas de alto nivel. De igual manera se emplearon como criterios de búsquedas las palabras claves relacionadas al tema, las cuales permitieron realizar la exploración exhaustiva en los buscadores electrónicos, y así obtener resultados concretos e información de mejor calidad. La plataforma Springerlink (2020) fundamenta que las palabras clave son una herramienta para ayudar a los indexadores y motores de búsqueda a encontrar artículos relevantes, si los motores de búsqueda de bases de datos pueden encontrar manuscrito de

revista, los lectores podrán encontrarlo también, aumentando el número de personas que lean un manuscrito y facilitando el proceso de indagación.

2.1.1.3. SELECCIÓN DE LOS ESTUDIOS

La elección inicial se realiza basándose en primera instancia en los criterios de inclusión, posteriormente se realiza una lectura en la descripción de los resúmenes y títulos de la información disponible para poder identificar los artículos potencialmente elegibles. Una vez culminado el proceso anterior, se examinan por completo los artículos escogidos y se ejecuta una selección final por medio de los criterios de inclusión y así obtener la información pertinente que respondan claramente la pregunta clínica planteada, en efecto, es ventajoso el uso de diagramas de flujo para demostrar el proceso de selección de artículos, donde se especifica desde el número inicial de artículos potencialmente elegibles según la búsqueda realizada hasta los finalmente incluidos (Moreno, 2018).

Los problemas que surjan entre los revisores pueden ser resueltos por consentimiento (entre revisores) por un tercer revisor experto en el tema (Fernández et al, 2019). Posteriormente, una vez que se tenga el número final de estudios que se incluirán para el análisis se seleccionaron aquellos documentos que cumplieron con los criterios establecidos, teniendo como resultado, documentos científicos útiles para los fines del trabajo de titulación.

2.1.1.4. EXTRACCIÓN DE LOS DATOS

Una vez finalizada la selección de las investigaciones, se debe obtener toda la información referente a la pregunta: quiénes y cuántos participaron, cuál fue la intervención, cuáles fueron los resultados medidos, entre otros. Este apartado se puede realizar de dos formas: a) un revisor sustrae los datos y otro revisa y verifica la información; o bien, b) dos revisores extraen los datos de manera independiente para después comparar la información (Fernández et al, 2019). Para registrar de manera ordenada estos datos extraídos, fueron tabulados en un formulario de recolección de datos, de tal forma que estos datos están resumidos de manera ordenada y oportuna para su entendimiento, esto con el fin de presentar la información y aportes relacionados al tema de titulación para

posteriormente evaluar en la última etapa de la metodología aquellas perspectivas que servirán dentro del trabajo.

2.2. DETERMINACIÓN DE ALGORITMOS PARA LA CREACIÓN DEL MODELO

2.2.1. RESUMEN Y DIFUSIÓN DE LOS RESULTADOS

Consiste en fusionar estadísticamente los resultados de diversos estudios independientes, pero en cierta medida combinables entre sí, con el objetivo de verificar si existe un efecto y qué tan grande o significativo puede ser este al ser evaluado (Páramo, 2020). Según Fernández et al (2019) los hallazgos se sintetizan empleando la estadística descriptiva (numérica) para los datos cuantitativos como metodología para la síntesis del conocimiento y un análisis temático para los datos cualitativos. No obstante, de ser necesario antes de iniciar con la redacción del manuscrito es recomendable que se vuelva a realizar la búsqueda en las bases de datos electrónicas para capturar estudios publicados recientemente.

2.3. OBTENCIÓN DEL CONJUNTO DE DATOS

En coordinación con el Director de la Carrera de Computación el Mgtr. Joffre Moreira Pico, se solicitaron los registros históricos de la Estación Meteorológica de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López, ubicada en el sitio El Limón, en el cual, se obtuvieron los reportes mensuales a partir del 1 septiembre del 2010 hasta el 30 junio del 2019 con las siguientes medidas: humedad relativa, temperatura máxima, temperatura mínima, temperatura ambiente, velocidad del viento, evaporación y precipitación, siendo la fuente principal para el desarrollo del trabajo. Por consiguiente como fuente secundaria, se descargaron los registros históricos del Visor de Acceso a Datos de Energía (Power Data Access Viewer) de la Administración Nacional de la Aeronáutica y del Espacio más conocida como NASA (National Aeronautics and Space Administration) (**Anexo 2B**), este sitio es un proyecto de predicción de los recursos energéticos mundiales, se inició para mejorar el conjunto de datos de energía renovable actual y crear nuevos conjuntos de datos a partir de nuevos sistemas satelitales, dirigiéndose a tres comunidades de usuarios: Energía

Renovable, Edificios Sostenibles y Agroclimatología (Administración Nacional de la Aeronáutica y del Espacio [NASA], 2020) obteniéndose los registros históricos de la localidad de Calceta a partir del 1 de enero del 2010 hasta el 30 de junio del 2020 con las siguientes medidas: precipitación, humedad relativa, velocidad del viento, temperaturas máximas y temperaturas mínimas.

Luego, se analizaron las variables meteorológicas obtenidas de ambas fuentes, en el cual, se organizó la información recolectada en el programa Microsoft Excel para la preparación del conjunto de datos en formato CSV (valores separados por comas) siendo un tipo de extensión de archivos que permite almacenar información y manipularla en los diferentes lenguajes de programación de inteligencia artificial, utilizándose específicamente Python debido que posee un sinnúmero de librerías que agilizan el proceso exploratorio de los datos ofreciendo una gran profundidad en el análisis y en la detección de posibles anomalías y errores de los mismos. Para la selección de las variables a utilizar, los autores emplearon aquellas más utilizadas en las investigaciones selectas adicionando también aquellas que no frecuentaban en el proceso de revisión sistemática (capítulo anterior), esto indica que se aprovechó toda la información recolectada para su procesamiento en la elaboración del modelo.

Una de las principales características de estos datos recolectados, es que al ser registros históricos tomados diariamente adoptan la característica de una serie temporal, es decir, un conjunto de observaciones medidas de forma secuencial a lo largo del tiempo (Chatfield, 2000, como se citó en López, 2017) y según Dávila (2020) los procesos que son series de tiempo frecuentemente presentan una tendencia, sea al crecimiento o decrecimiento, esto indica se pueden estudiar dichas tendencias pasadas para a partir de ello pronosticar nuevos datos y su comportamiento a futuro. En cuanto a las variables meteorológicas definidas, se realizó una matriz de correlación de Pearson, siendo un indicador usado para describir cuantitativamente la fuerza y dirección de la relación entre dos variables numéricas de distribución normal, ayudando a establecer sus tendencias, a lo que también se denomina covarianza (García, 2019).

Tabla 2.2. Interpretación del coeficiente de correlación

0	Sin correlación
± 0.20	Correlación débil
± 0.50	Correlación moderada
± 0.80	Correlación buena
1	Correlación perfecta

Fuente: García (2019)

Según García (2019), el factor de correlación es simbolizado con la letra “r” en el cual, pueden tomar valores de -1 y $+1$. Un resultado de valor 0 significa que no hay correlación, es decir, una variable no se relaciona con el proceder de la otra variable, por ello, es recomendable que el coeficiente de correlación sea lo más cercano a 1, mayor la fuerza de asociación (**tabla 2.2**). No obstante, se pudo determinar la relación existente entre las variables recopiladas de ambos sets, de tal modo que si el coeficiente es mayor o igual a $r = 0.80$ entre los datos, el modelo se lo establece para un pronóstico multivariante caso contrario si el coeficiente de correlación se encuentra por debajo del valor establecido la predicción se la construye de carácter invariante debido que los comportamientos de los datos serían independiente entre uno y otros en cuanto a su distribución se refiere.

2.4. CONSTRUCCIÓN DEL MODELO

En esta fase se detalla el proceso para la construcción del modelo de predicción en el cual se aplicó el modelo/ algoritmo definido en la etapa de análisis y difusión de resultados, no obstante, se empleó el aprendizaje supervisado siendo una técnica para deducir fenómenos o acontecimientos a partir de datos de entrenamiento, en la que se entrena un modelo con ejemplos predefinidos y luego se usa ese modelo para predecir los resultados de los datos de entrada que le pasemos, y mediante un test de validación nos permitirá afinar los parámetros del algoritmo para obtener el resultado esperado (Sanz, 2016).

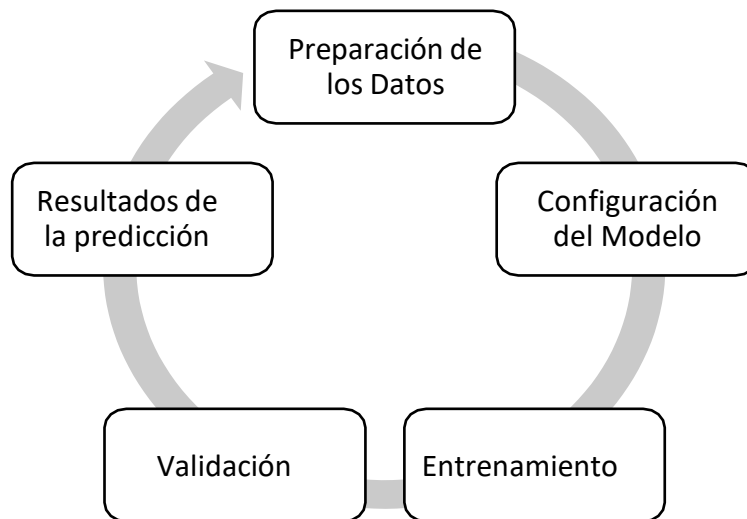


Figura 2.1. Flujo de ejecución para la construcción del modelo

Fuente: Los autores

Para la construcción del modelo se llevaron a cabo los procesos correspondientes al flujo (figura 2.1) describiéndose a continuación:

- **Preparación de los datos:** se configuró los datos periféricos que el modelo va a procesar desde el dataset en el cual se parametriza la cantidad de valores pasados de las series de tiempo de las variables empleadas para la predicción.
- **Configuración del modelo:** implica instanciar la clase mediante la cual se implementa el algoritmo en cuestión, considerando los parámetros que le son propios a su tipo.
- **Entrenamiento:** el algoritmo experimenta con el dataset de entrenamiento con la finalidad de aprender el comportamiento de la serie que se le va a pasar, comúnmente todos los datos se los dividen en subconjuntos normalmente con una proporción del 75 al 80 %.
- **Validación:** Por lo general se utiliza un 20 al 25 % para evaluación o testeo con finalidad de ajustar la calidad de predicción del modelo entrenado al comparar las predicciones en el conjunto de datos de evaluación con valores verdaderos (conocidos como datos reales).
- **Resultados de la predicción:** empleando una variedad de métricas de error se deduce si el modelo posee un buen rendimiento, con base a ello, se presentarán los resultados obtenidos de las variables predichas.

CAPÍTULO III. DESCRIPCIÓN DE LA EXPERIENCIA

En esta sección se exponen y describen los resultados obtenidos en el presente trabajo de titulación, mismo que están relacionados con los objetivos planteados, siguiendo la misma organización general del desarrollo metodológico de la intervención abarcado en la sección anterior.

3.1. REVISIÓN DEL ESTADO DEL ARTE

A través de las fases de la metodología de revisión sistemática se pudo llevar a cabo el proceso de revisión del estado del arte de los modelos de predicción climática de manera detallada y ordenada, de tal forma, que permitió a los autores recabar información precisa para los fines del trabajo de titulación, en las fases de la metodología mencionada se obtuvo lo siguiente:

3.1.1. ELABORACIÓN DE LA PREGUNTA

Los autores formularon las siguientes preguntas de investigación, mismas que se presentan a continuación:

Tabla 3.1. Formulación de las Preguntas de Investigación

Pregunta 1	¿Cuáles son los modelos computacionales más empleados en las predicciones climáticas?
Pregunta 2	¿Cuáles son los algoritmos que emplean estos modelos computacionales en las predicciones climáticas?
Pregunta 3	¿Cuál fue el modelo y algoritmo con mejor porcentaje de efectividad en las predicciones climáticas?
Pregunta 4	¿Cuáles fueron las herramientas empleadas para la construcción del modelo y algoritmo?

Fuente: Los autores

3.1.2. ESTABLECIMIENTO DE LOS CRITERIOS DE INCLUSIÓN Y BÚSQUEDA SISTEMÁTICA

Para el desarrollo de esta fase se establecieron los siguientes criterios inclusión y búsqueda sistemática:

Tabla 3.2. Criterios de inclusión y búsqueda sistemáticas

Criterios de inclusión	Artículos científicos – Tesis	2015 - 2020	español	inglés
Palabras claves	Modelo de predicción	Pronóstico del clima	Series de tiempo climática	Aprendizaje automático

Fuente: Los autores

Los criterios definidos (**tabla 3.2**) facilitaron a los autores la búsqueda de las investigaciones en distintas fuentes de información, se incluyeron los documentos de tipo artículos científicos y tesis en los idiomas español o inglés publicados dentro de los años 2015-2020, no obstante, se excluyeron los documentos que sean de tipo monografías, informes, y blogs publicados, además se descartaron las investigaciones que no cumplen con el año de publicación definidos, por lo consiguiente, para la realización de dicha búsqueda las palabras claves determinadas facilitaron el proceso de filtrado de los artículos científicos e investigaciones relacionados al tema de estudio.

3.1.3. REVISIÓN Y SELECCIÓN DE ESTUDIOS

Para el proceso de revisión en las bases de datos electrónicas se generó varias cadenas de búsqueda utilizando las siguientes palabras claves: **“modelo de predicción, pronóstico del clima, series de tiempo climática, aprendizaje automático”**, en Google Scholar se reflejaron 1.360 resultados y en Springerlink 91 resultados referentes al tema, obteniéndose 1451 resultados entre ambas fuentes, luego, aplicando los criterios de inclusión definidos **“artículos científicos – tesis, 2015 – 2020, español o inglés”** se logró extraer una muestra de 102 artículos publicados en los periodos 2015 – 2020 de los resultados totales obtenidos en el proceso anterior, de los cuales 78 artículos correspondieron a Google Scholar y 24 investigaciones a Springerlink; posteriormente, para la etapa de preselección se analizaron los títulos y resúmenes de la muestra obtenida, lográndose aceptar 18 artículos correspondiente a Google Scholar y se rechazaron 60 artículos de poca relevancia, se repitió el mismo proceso con los documentos de Springerlink lográndose obtener 12 artículos de interés y rechazándose 12 investigaciones teniendo un total de 30 artículos entre ambas fuentes. Para la selección final, se

procedió a dar lectura a las 30 investigaciones a texto completo, y de modo independiente los autores efectuaron dicha revisión, en el cual, se consiguió seleccionar 16 artículos que registraron aportaciones de interés para el presente tema de estudio y se descartaron 14 artículos que si bien cumplieron con los criterios definidos no tuvieron aportes notables a tomar en cuenta para los propósitos del trabajo de titulación. Se realizó el siguiente flujo (**Figura 3.1**) para la representación de la selección de los documentos dentro de la revisión:

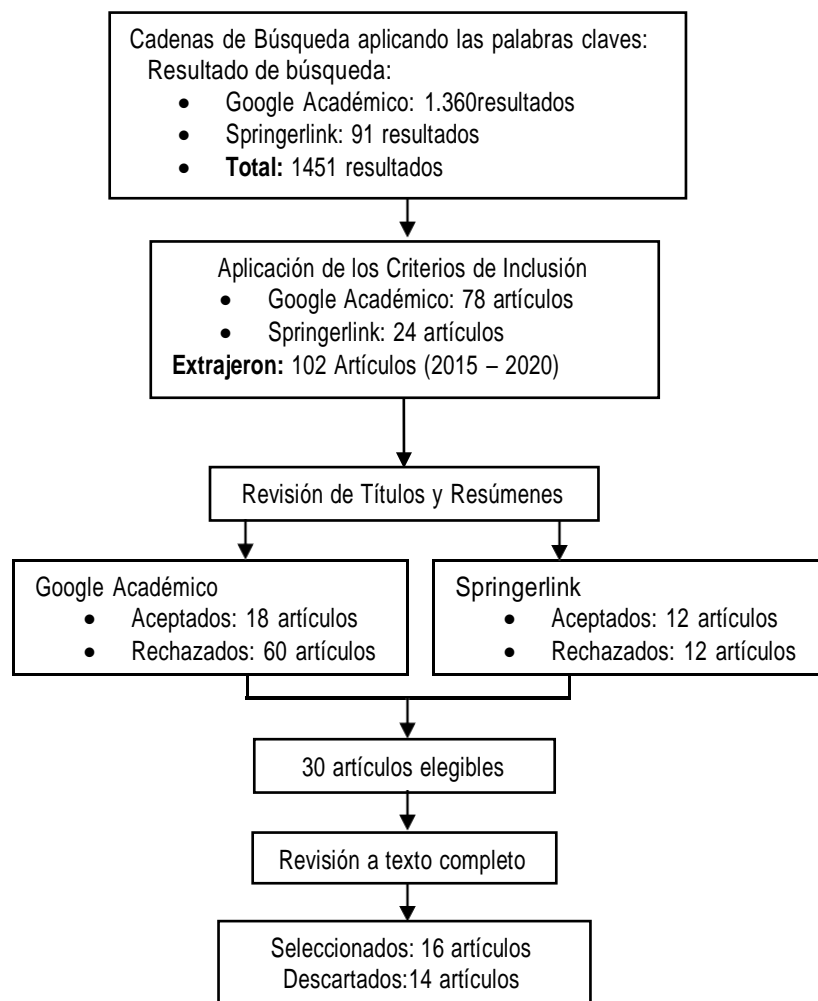


Figura 3.1. Proceso de selección de los artículos
Fuente: Los autores

3.1.4. EXTRACCIÓN DE DATOS

Los datos extraídos de los artículos seleccionados fueron los siguientes: año, autor, título, descripción, modelo, algoritmo, variables, efectividad, métricas y herramienta. La revisión fue útil para proporcionar indicaciones metodológicas que guíen la investigación, en el cual, la documentación detallada puso en

contexto a los autores con lo que se ha aportado dentro del campo estudio, contribuyendo de manera directa la aclaración del problema planteado, aportando técnicas y sugerencias para poder llevar a cabo de manera eficiente el desarrollo de la investigación de interés (**Anexo 1**).

3.2. DETERMINACIÓN DE ALGORITMOS PARA LA CREACIÓN DEL MODELO

3.2.1. RESUMEN Y DIFUSIÓN DE LOS RESULTADOS DE LA REVISIÓN SISTEMÁTICA

3.2.1.1. ¿CUÁLES SON LOS MODELOS COMPUTACIONALES MÁS EMPLEADOS EN LAS PREDICIONES CLIMÁTICAS?

Los resultados obtenidos en cada artículo fueron resumidos a través del siguiente análisis estadístico, determinando lo siguiente:




Gráfico 3.1. Modelos Computacionales empleados para las predicciones relacionadas al clima
Fuente: Los autores

Entre los tipos de modelos computacionales encontrados para las predicciones del clima se destacaron las redes neuronales artificiales, empleándose variantes de estas mencionadas para los diferentes pronósticos meteorológicos existentes (**gráfico 3.1**), en dicho campo, cinco artículos científicos analizados hacían mención a la Red Neuronal Recurrente para su empleabilidad, siendo correspondiente a un 31% de la muestra de los estudios seleccionados, en ese

mismo sentido cuatro estudios hicieron referencia al uso de la Red Neuronal Feedforward y de igual manera mencionaron a la Red Neuronal Perceptrón Multicapa las cuales competen al 25% de las muestras estudiadas. No obstante, tres de los estudios considerados, nombraron al modelo estadístico ARIMA, mismo que emplea técnicas de aprendizaje automático (machine learning) para los pronósticos climáticos, perteneciendo al 19% de las investigaciones restante.

3.2.1.2. ¿CUÁLES SON LOS ALGORITMOS QUE EMPLEAN ESTOS MODELOS COMPUTACIONALES EN LAS PREDICCIONES CLIMÁTICAS?




Gráfico 3.2. Porcentajes de Efectividad de la Red Neuronal Recurrente con el algoritmo LSTM.

Fuente: Los autores

En el **(gráfico 3.2)** con respecto a la red neuronal recurrente observamos que el algoritmo LSTM (Long Short Term Memory) tiene un rango efectividad entre el 98% hasta el 70% con las predicciones.




Gráfico 3.3. Porcentajes de Efectividad de la Red Neuronal Feedforward con el algoritmo de Backpropagation

Fuente: Los autores

Entre los algoritmos utilizados en las redes neuronales, se observó la empleabilidad del algoritmo Backpropagation, este consiste en utilizar el error generado por la red y propagarlo hacia atrás, es decir, reproducirlo hacia las neuronas de las capas anteriores (Polo, 2015), en lo que respecta en su usabilidad con la Red Neuronal Feedforward (**gráfico 3.3**), se observa que alcanzó rangos del 86% hasta el 95,5% de efectividad en sus predicciones según estudios analizados.

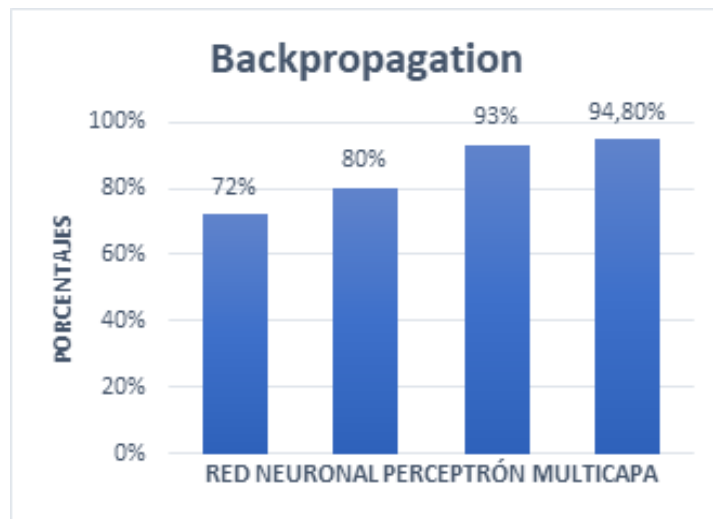


Gráfico 3.4. Porcentajes de Efectividad de la Red Neuronal Multicapa con el algoritmo de Backpropagation
Fuente: Los autores

De la misma manera, como puede observarse en la ilustración (**gráfico 3.4**) el algoritmo de Backpropagation empleado con Red Neuronal Multicapa alcanzó porcentajes de efectividad entre 72% hasta el 94.80% obteniendo resultados apropiados en las predicciones realizadas.




Gráfico 3.5. Porcentajes de Efectividad del modelo ARIMA empleando los algoritmos de SVM y Naive Bayes.
Fuente: Los autores

Como se observa en la ilustración (**gráfico 3.5**) los algoritmos SVM alcanzaron un porcentaje de efectividad en las predicciones del 67%, mientras que el Naive Bayes obtuvo un porcentaje de 87%, esto en conjunto con el modelo ARIMA.




Gráfico 3.6. Porcentajes de Efectividad de Efectividad del modelo ARIMA empleando el algoritmo Autoregressive Integrated Moving Average
Fuente: Los autores

Por último, como se puede observar en la ilustración (**gráfico 3.6**) el algoritmo Autoregressive Integrated Moving Average propio del modelo ARIMA en dos investigaciones obtuvieron rangos de efectividad del 76,09% y el 80% en las predicciones. Este algoritmo es usualmente utilizado para análisis de series temporales, es decir, regularidades en el comportamiento a través del tiempo de una o más variables en la que podamos extraer una estructura probabilística (Cazalla, 2015).

3.2.1.3. ¿CUÁL FUE EL MODELO Y ALGORITMO CON MEJOR PORCENTAJE DE EFECTIVIDAD EN LAS PREDICCIONES CLIMÁTICAS

Durante el proceso de Revisión Sistemática se evidenció una gran cantidad de variantes de modelos (**gráfico 3.1**) que se pueden emplear para el estudio de series de tiempo, sin embargo, durante el proceso de experimentación con una Red Neuronal tipo Feedforward y Perceptrón Multicapa aplicando el algoritmo Backpropagation se obtuvieron resultados poco favorables para los fines del trabajo (**Anexo 5A y 5B**), notándose como no lograron aprender ni aproximarse a la secuencia real de los datos, esto indica que si bien estos alcanzaron porcentajes de efectividad altos en los documentos obtenidos, no siempre se

suelen adaptar a todos los escenarios particulares de una investigación, ya sea por las características de los datos adquiridos o por las limitaciones que estos modelos pueden tener presentes. Por estas razones mencionadas, se determinó utilizar la Red Neuronal Recurrente junto con el algoritmo y estructura LSTM debido que según García (2019) declara que este tipo de red han obtenido mejores resultados que cualquiera de los otros métodos comparados ya que son capaces de extraer la información temporal de los datos y son un tipo especial de red neuronal (RNN) capaces de aprender tendencias de datos a largo plazo, además durante el proceso bibliográfico se pudo establecer que la eficiencia de la red seleccionada obtuvieron rangos de efectividad notables que van del 70% hasta el 98%, por esta razón se llegó a la conclusión de usar este tipo de red neuronal artificial en la predicción climática debido que las características de los datos obtenidos son de tipo serie de tiempo por el cual este modelo es el idóneo para este estudio.

3.2.1.4. ¿CUÁLES FUERON LAS HERRAMIENTAS EMPLEADAS PARA LA CONSTRUCCIÓN DEL MODELO Y ALGORITMO?




Gráfico 3.7. Lenguajes de Programación empleados en la elaboración de modelos computacionales
Fuente: Los autores

Entre los lenguajes de programación empleados para la elaboración de modelos computacionales, ocho estudios especificaron que emplearon Python (**gráfico 3.7**),

siendo uno de los más destacados a emplear ya que posee un sinnúmero de bibliotecas o herramientas para el estudio y análisis de datos.

3.2.1.5. MÉTRICAS




Gráfico 3.8. Métrica empleada para la efectividad de los modelos computacionales
Fuente: Los autores

Los dieciséis estudios puntualizaron el uso de la métrica de error cuadrático medio (**gráfico 3.8**), permitiendo calcular el margen de error de los modelos y la efectividad del mismo, detallando que, mientras más bajo sea este valor mejor será el resultado del pronóstico.

3.2.1.6. VARIABLES CLIMÁTICAS




Gráfico 3.9. Variables más utilizadas en los artículos científicos
Fuente: Los autores

Entre las variables más utilizada para la elaboración de los modelos computacionales tenemos con un 31% la precipitación y la temperatura, con un

24 % la humedad, y por último con un 14% la velocidad del viento como se aprecia en la ilustración (**gráfico 3.9**), siendo estas las principales intervinientes dentro de la elaboración de la investigación.

3.3. OBTENCIÓN DEL CONJUNTO DE DATOS

Se realizó un pre-procesamiento de los sets (**anexo 2A y 2C**) para poder corroborar datos faltantes o nulos que suelen presentarse, lo cual, pueden generar una afectación significativa al modelo predictivo en los resultados. Para ello aprovechamos las librerías de Python específicamente Pandas para el análisis y manipulación de datos obteniendo lo siguiente:

```

DATASET-ESPAM
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 3225 entries, 0 to 3224
Data columns (total 7 columns):
#   Column          Non-Null Count  Dtype
---  ---
0   humedad_rela    3225 non-null   float64
1   temp_min        3225 non-null   float64
2   temp_max        3225 non-null   float64
3   temp_ambiente   3225 non-null   float64
4   evaporacion     3225 non-null   float64
5   precipitacion   3225 non-null   float64
6   viento_km       3225 non-null   float64
dtypes: float64(7)
memory usage: 176.5 KB

DATASET-POWER DATA
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 3834 entries, 0 to 3833
Data columns (total 5 columns):
#   Column          Non-Null Count  Dtype
---  ---
0   precipitacion    3834 non-null   float64
1   velocidad_viento 3834 non-null   float64
2   humedad          3834 non-null   float64
3   temp_max         3834 non-null   float64
4   temp_min         3834 non-null   float64
dtypes: float64(5)
memory usage: 149.9 KB

```

Figura 3.2. Exploración de los Datos
Fuente: Los autores

Como se puede visualizar (**figura 3.2**), la Estación Meteorológica de la ESPAM – MFL está compuesta por 7 variables con 3325 registros, no existen datos faltantes y son de tipo flotante, de igual manera el set secundario está compuesto por 5 variables con 3834 registros, no tiene datos nulos y son de tipo flotante. En el contexto de que se emplearon dos fuentes de datos distintas pero pertenecientes a una misma zona, se resumen en el siguiente apartado las variables similares y diferentes en los sets de datos:

Tabla 3.4. Variables existentes en los datasets

Datasets	Temp. Máxima	Temp. Mínima	Temp. Ambiente	Humedad	Velocidad del viento	Evaporación	Precipitación
ESPAM	x	x	x	x	x	x	x
PowerData	x	x		x	x		x

Fuente: Los autores

Dentro del marco de trabajo para la selección de las variables a emplear con ayuda de las documentaciones resumidas en el proceso sistemático, se identificó que las temperaturas, humedad, velocidad del viento y precipitaciones son las que más estuvieron inmersas en su utilización dentro de las investigaciones analizadas. A partir de los datos presentados (**tabla 3.4**), se evidencia que las ya mencionadas están disponibles en ambos sets, siendo ventajoso para su utilización, no obstante, también se emplearon aquellas que no fueron resaltadas dentro de los trabajos examinados, sirviendo como datos adicionales para la predicción. Cabe considerar que la utilización de dos conjuntos de datos es con el propósito de obtener más información y poder experimentar si el modelo puede adaptarse a cambios cuando estas medidas varían en las fuentes o zonas recopiladas, finalmente, con lo expuesto quedó elaborado el conjunto de datos en formato csv (**anexo 3A y 3B**).

Posteriormente, a través de un análisis estadístico de los datos se logró comprobar cuán correlacionadas están las variables entre sí, con el objetivo de conocer aquellas que guardan un coeficiente de relación con un $r=0.80$ o lo más cercano a 1; de igual manera se hizo uso de la librería Pandas.

	humedad_rela	temp_max	temp_min	temp_ambiente	evaporacion	precipitacion	viento_km
humedad_rela	1.000000	-0.178999	0.306780	-0.021411	-0.408348	0.198730	-0.109270
temp_max	-0.178999	1.000000	0.129814	0.136690	0.440648	-0.005710	-0.011597
temp_min	0.306780	0.129814	1.000000	0.122199	-0.256701	0.219853	-0.113950
temp_ambiente	-0.021411	0.136690	0.122199	1.000000	0.076443	0.019212	0.123159
evaporacion	-0.408348	0.440648	-0.256701	0.076443	1.000000	-0.256566	0.273972
precipitacion	0.198730	-0.005710	0.219853	0.019212	-0.256566	1.000000	0.002877
viento_km	-0.109270	-0.011597	-0.113950	0.123159	0.273972	0.002877	1.000000

Figura 3.3. Matriz de correlación de Pearson - Set_ESPAM
Fuente: Los autores

Como se puede apreciar (**figura 3.3**) los datos demuestran que no existe correlación significativa entre variables, siendo el coeficiente $r=0.44$ entre la evaporación y temperatura máxima el valor más alto en todo el conjunto y con ayuda de la librería Matplotlib se graficó la dispersión de los datos para una mejor interpretación (**anexo 4A**), demostrando la poca linealidad de los mismos en su

dispersión, reflejando que un pronóstico multivariable no sería el indicado en este caso, debido que la serie de tiempo tiende a tener comportamientos no lineales en sus patrones, lo cual refleja que las variables del set de datos son independientes entre sí.

	precipitacion	velocidad_viento	humedad	temp_max	temp_min
precipitacion	1.000000	-0.010008	0.553283	-0.523535	0.388616
velocidad_viento	-0.010008	1.000000	0.083932	-0.106921	-0.143795
humedad	0.553283	0.083932	1.000000	-0.916828	0.445106
temp_max	-0.523535	-0.106921	-0.916828	1.000000	-0.230236
temp_min	0.388616	-0.143795	0.445106	-0.230236	1.000000

Figura 3.4. Matriz de correlación de Pearson - Set_PowerData
Fuente: Los autores

De igual manera las variables del set secundario (**figura 3.4**) demuestran que no poseen valores altos de correlación, es decir, cercanos a 1, siendo el coeficiente $r=0.55$ el valor más alto y perteneciente a la precipitación y la humedad, logrando interpretarse que la dispersión de esta sección de datos no refleja altos niveles de relación entre sí, debido que los patrones tienen comportamientos independientes dentro de la serie de tiempo. Sin embargo, los puntos que ubican entre la humedad y la temperatura máxima indica que existe una correlación negativa fuerte entre las variables, es decir, que a medida que una variable aumenta en el eje X_i , tienden a puntuar valores pocos significativos en el eje Y_i y los que registran valores bajos en X_i tienden a obtener valores altos en Y_i , esto se observa en la interpretación de los gráficos (**anexo 4B**) que estas últimas mencionadas tienen dicho comportamiento inversamente entre sí.

3.4. CONSTRUCCIÓN DEL MODELO

El desarrollo del modelo de predicción se lo realizó bajo el entorno de Jupyter Notebook empleando la versión de Python 3.7.5 entre las principales librerías intervinientes e instaladas para la realización del trabajo fueron las siguientes:

Tabla 3.5 Librerías utilizadas para el desarrollo del modelo

Numpy	Provee objetos tipo arreglos multidimensionales de datos de alto rendimiento, además de herramientas asociadas a su manejo.
Matplotlib	Librería para trazado de gráficos.
TensorFlow	Es una librería desarrollada por Google para trabajar en Aprendizaje Automático, caracterizada principalmente por su capacidad de construir y entrenar redes neuronales de variados tipos.

Fuente: (González, 2017)

Una vez instalados los paquetes determinados (**tabla 3.5**), se muestra como se procesaron las variables intervinientes en la construcción del modelo:

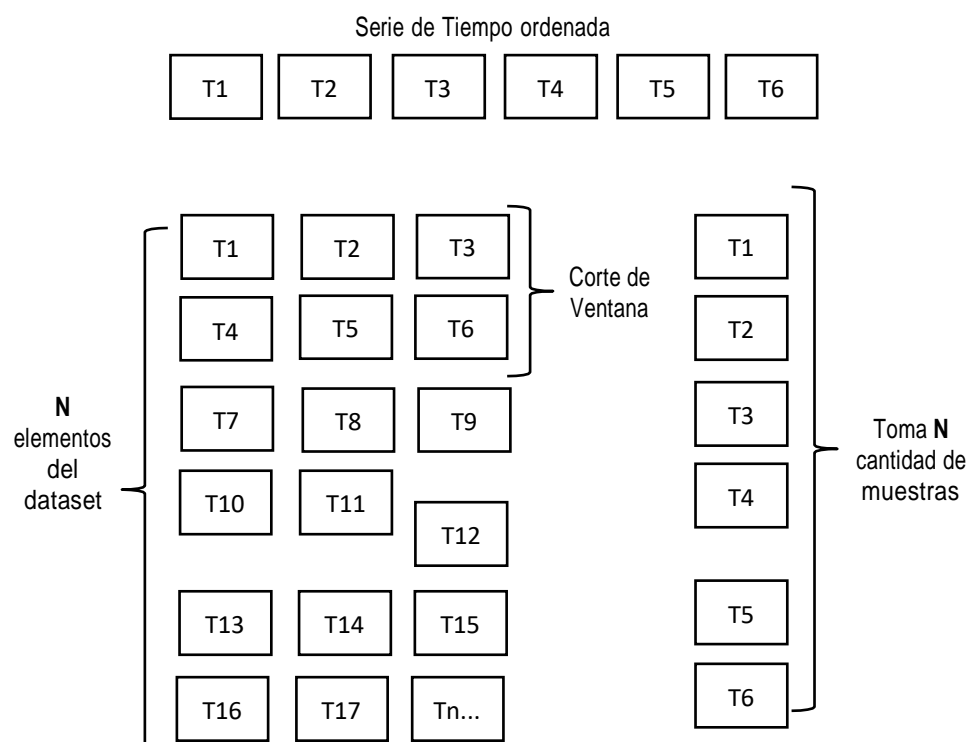


Figura 3.5. Procesamientos de los datos

Fuente: Los autores

Como se puede observar en la ilustración (**figura 3.5**), se determinó en primera instancia que por cada 1000 elementos del conjunto de datos un “batch_size” o cantidad de muestras de tamaño 100, que se propagará a través de la red donde el algoritmo toma dicho valor (del 1 al 100) del conjunto de datos para entrenar, repitiendo el proceso (101 al 200) hasta completar el total de datos dentro del conjunto, y para dar más solidez a las entradas del modelo, se incluyó una ventana “window_size” de tamaño 120, en el cual, incluirá el paso de tiempo actual junto con los pasos de tiempo anteriores con la finalidad de que el algoritmo pueda aprender eficientemente los valores procesados, por último para obtener el elemento de salida, se especifica la columna donde se encuentre el dato que se desea predecir por medio de una variable declarada.

```

batch_size = 100
window_size = 120
shuffle_buffer_size = 1000

name = "dataSET_ESTACION_ESPAM.csv" # primer dataset
name = "dataSET_POWERDATA.csv" # segundo dataset

df = pd.read_csv(name, sep=';')
print(list(df.columns))

# primer dataset
nombres = ['Humedad Relativa', 'Temperatura Minima',
           'Temperatura Maxima', 'Precipitacion', 'Velocidad del viento']
columnas = ['humedad_rela', 'temp_min', 'temp_max', 'precipitacion', 'viento_km']

# segundo dataset
nombres = ['Precipitacion', 'Velocidad del viento',
           'Humedad', 'Temperatura Maxima', 'Temperatura Minima']
columnas = ['precipitacion', 'velocidad_viento', 'humedad', 'temp_max', 'temp_min']

n = 3
df = df[columnas]

columna = columnas[n]
titulo = nombres[n]
print(n, columna, titulo)

```

Figura 3.6. Código en Python de la configuración de los parámetros que serán procesados

Fuentes: Los autores

El modelo determinado en la etapa de la revisión sistemática fue el de una red neuronal recurrente con una estructura LSTM, fue configurado de la siguiente manera:

```
def modelo():
    model = tf.keras.models.Sequential([
        tf.keras.layers.Conv1D(filters=60, kernel_size=5,
                               strides=1, padding="causal",
                               activation="relu", input_shape=[None, 1]),
        tf.keras.layers.LSTM(60, return_sequences=True),
        tf.keras.layers.LSTM(60, return_sequences=True),
        tf.keras.layers.Dense(30, activation="relu"),
        tf.keras.layers.Dense(10, activation="relu"),
        tf.keras.layers.Dense(15),
        tf.keras.layers.Lambda(lambda x: x * 400)
    ])
    return model
```

Figura 3.7. Código fuente en Python de la estructura de la red neuronal recurrente – LSTM

Fuente: Los autores

Esta red neuronal está compuesta por una capa convolucional de una dimensión “CONV1D” de 60 filtros, seguida de dos capas LSTM manteniendo ambas en 60 bloques, más tres capas del tipo Dense de 30, 10 y 15 neuronas en ese orden, empleando como función de activación “Relu” para propagar la información desde las neuronas de entradas hasta las de salidas como se puede apreciar en la ilustración **(figura 3.7)**.

Una vez definida la estructura de la red recurrente – LSTM se llevó a cabo el entrenamiento de la misma probando cada una de las variables disponibles, en ese sentido, se emplearon el 75% de los datos totales para el aprendizaje de los patrones que posee la serie de tiempo en los datasets y el 25% restante para el testeo o validación con cual podremos constatar la predicción del modelo, cabe agregar que para determinar las variables que tuvieron un mejor rendimiento durante esta etapa se las evaluaron de manera individual con dicho propósito.

Model: "sequential_12"

Layer (type)	Output Shape	Param #
conv1d_12 (Conv1D)	(None, None, 60)	360
lstm_24 (LSTM)	(None, None, 60)	29040
lstm_25 (LSTM)	(None, None, 60)	29040
dense_36 (Dense)	(None, None, 30)	1830
dense_37 (Dense)	(None, None, 10)	310
dense_38 (Dense)	(None, None, 15)	165
lambda_12 (Lambda)	(None, None, 15)	0
Total params: 60,745		
Trainable params: 60,745		
Non-trainable params: 0		

Figura 3.8. Resumen del entrenamiento de la red neuronal recurrente – LSTM

Fuente: Los autores

Esta red neuronal (**figura 3.8**) obedece a la estructura de la Red Neuronal Recurrente (RNN) – LSTM establecida, la cual pudo entrenar con éxito 60,745 parámetros totales, no obstante, dado que el algoritmo debe obedecer el comportamiento de los patrones el estudio de su precisión se basará en la medida del Error Cuadrático Medio, lo que nos ayudará a determinar la diferencia entre el valor a estimar y lo que se estima.

Tabla 3.6. Error Cuadrático Medio obtenido durante el entrenamiento con 150 epochs

VARIABLES	ERROR CUADRÁTICO MEDIO	
	ESPAM	POWER DATA
Humedad	2,93	2,65
Temperatura Máxima	6,542	4,83
Temperatura Mínima	1,48	0,72
Precipitación	91,01	40,60
Velocidad del viento	6,037	0,18

Fuente: Los autores

Con 150 epochs establecidas en la fase de entrenamiento se alcanzaron diferentes rangos de error en cuanto al aprendizaje de los patrones de la serie de tiempo (**tabla 3.6**), en cual se constató que las variables de la humedad en ambos sets obtuvieron valores de error aceptables en el aprendizaje de los patrones de la serie, seguido de las temperaturas (máximas y mínimas) podemos

notar que el modelo tuvo un mejor adiestramiento que la variable anterior, seguidamente, con la precipitación se adquirieron errores más altos a los anteriores y por último la velocidad del viento observamos que el modelo tuvo éxito para aprender el patrón de la serie de esta última mencionada.

También se experimentó con 2 variables adicionales del conjunto de datos de la estación meteorológica de la ESPAM-MFL con la finalidad de tomar en consideración con qué otros datos meteorológicos el modelo es capaz de seguir un patrón, en el cual, durante el proceso de entrenamiento se pudo obtener valores relativamente bajos de error como se puede observar a continuación:

Tabla 3.7. Variables adicionales empleadas en el entrenamiento

Variables	Error Cuadrático Medio
Temperatura Ambiente	2,32
Evaporación	3,798

Fuente: Los autores

Como se puede visualizar en la **(tabla 3.7)** el error cuadrático medio más bajo fue de la temperatura ambiente en comparación de la evaporación. A continuación, se mostrarán en color azul el 25% restante de los valores de cada variable, y en color naranja el 25% predicho por el modelo, basándose en el entrenamiento realizado sobre el 75%.




Gráfico 3.10. Valores Reales y Predichos de la Humedad Relativa

Fuente: Los autores




Gráfico 3.11. Valores Reales y Predichos de la Temperatura Máxima
Fuente: Los autores




Gráfico 3.12. Valores Reales y Predichos de la Temperatura Mínima
Fuente: Los autores

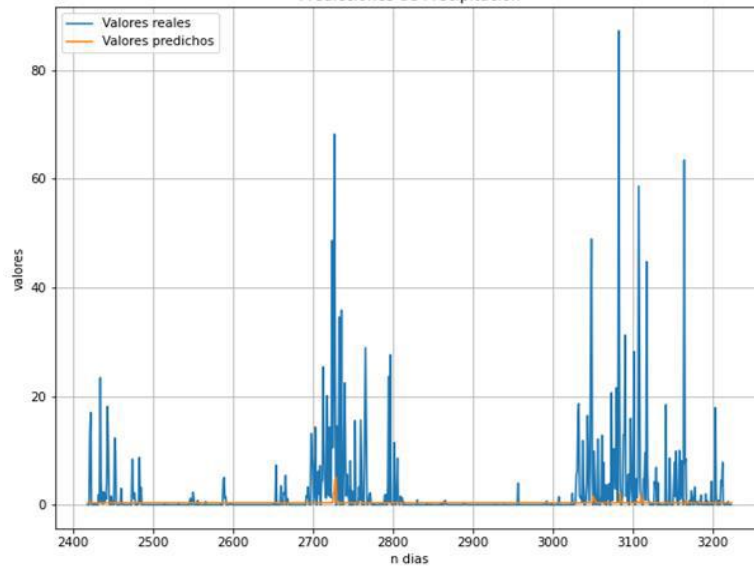


Gráfico 3.13. Valores Reales y Predichos de la Precipitación
Fuente: Los autores

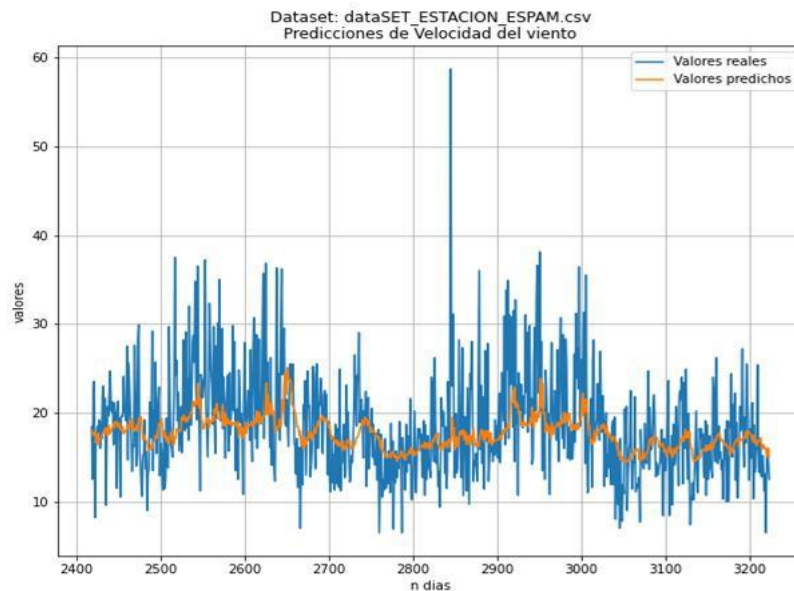


Gráfico 3.14. Valores Reales y Predichos de la Velocidad del Viento
Fuente: Los autores

En cuanto al conjunto de datos de la estación de meteorológica de la ESPAM – MFL , la red neuronal fue capaz de identificar los patrones de comportamiento de las series de tiempo, en dónde la precisión de modelamiento de cada variable tiene su propio comportamiento, no obstante, la eficiencia del pronóstico es directamente proporcional al nivel de error dado por el entrenamiento individual que se efectuó sobre las variables, siendo la humedad relativa (**gráfico 10**), la temperatura máxima (**gráfico 11**) y temperatura mínima (**gráfico 12**) con las que el modelo tuvo un mejor desempeño entre los valores reales y los predichos. Posteriormente, todo el proceso se lo repitió con los datos del segundo dataset obteniendo lo siguiente:




Gráfico 3.15. Valores Reales y Predichos de la Humedad Relativa
Fuente: Los autores




Gráfico 3.16. Valores Reales y Predichos de la Temperatura Máxima
Fuente: Los autores




Gráfico 3.17. Valores Reales y Predichos de la Temperatura Mínima
Fuente: Los autores




Gráfico 3.18. Valores Reales y Predichos de la Precipitación
Fuente: Los autores

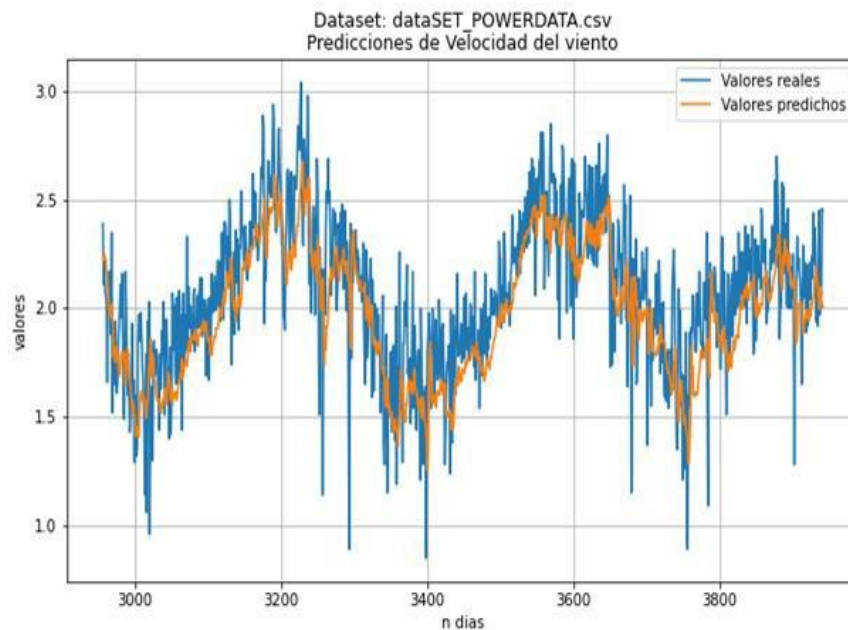


Gráfico 3.19. Valores Reales y Predichos de la Velocidad del Viento
Fuente: Los autores

En lo que conlleva a los resultados obtenidos con el segundo conjunto de datos, podemos observar que las variables en general tuvieron un mejor comportamiento en el reconocimiento de los patrones, denotando que la humedad (**gráfico 14**), la temperatura máxima (**gráfico 15**), la temperatura mínima (**gráfico 16**) y la velocidad del viento (**gráfico 18**) con la que el modelo obtuvo un mejor reconocimiento entre los patrones reales y predichos por el mismo.

Por último, se observó que el modelo no tuvo un rendimiento eficiente con la evaporación y en comparación a la temperatura ambiente esta última tuvo un desempeño medianamente bueno, sin embargo, denotamos en las gráficas que los valores predichos no se aproximan tanto a los valores reales de la serie de tiempo de estas variables.

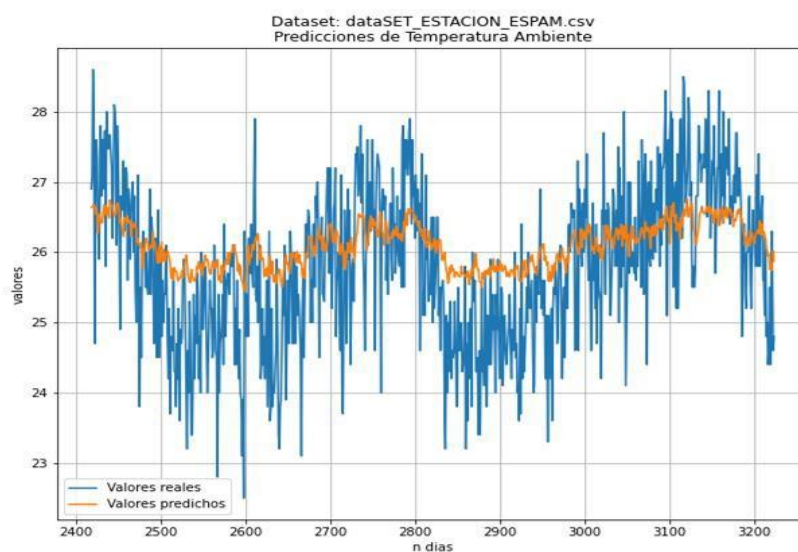


Gráfico 3.20. Valores Reales y Predichos de la Temperatura Ambiente
Fuente: Los autores

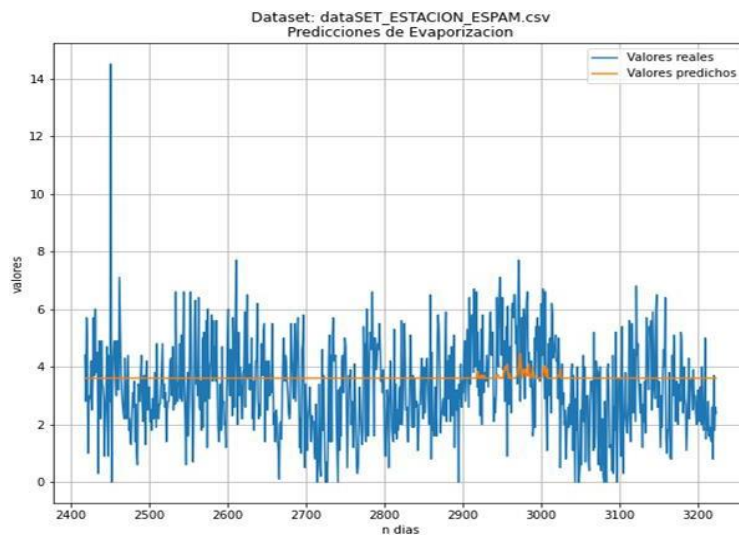


Gráfico 3.21. Valores Reales y Predichos de la Evaporación

Fuente: Los autores

Para el cálculo del rendimiento del pronóstico en términos porcentuales (%) durante el entrenamiento del modelo, se empleó el criterio del error absoluto porcentual (MAPE) para calcular la exactitud, lo cual estos valores irán apuntando cuán cercanos son los valores pronosticados con respecto a sus valores reales, es decir, apunta a cuan eficiente es el pronóstico (Núñez, 2019).

$$\text{Exactitud}\% = 100 - \text{MAPE}\%$$

Figura 3.9. Ecuación de exactitud (Núñez, 2019)

Esta ecuación permite calcular la precisión del modelo para conocer la aproximación del pronóstico como se muestra en la **(figura 3.9)**, teniendo como resultado un valor porcentual de qué tan efectivo fueron las variables empleadas al pronosticarlas.

Tabla 3.8. Precisión del modelo con los datos de la Estación Meteorológica de la ESPAM - MFL

Variables	MAPE	Exactitud
Humedad	10,73%	89,27%
Temperatura Máxima	8,00%	92,00%
Temperatura Mínima	9,39%	90,61%
Temperatura Ambiente	33,66%	66,34%
Velocidad del viento	25,91%	74,09%
Evaporación	47,42%	52,58%
Precipitación	23410,47%	-23,310.47%

Fuente: Los autores

Con los datos de la estación meteorológica de la ESPAM – MFL (**tabla 3.8**), las variables que obtuvieron un error aceptable fueron la humedad, la temperatura máxima y la temperatura mínima, también denotamos que la temperatura ambiente, la velocidad del viento y la evaporación obtuvieron un valor de error mayor en comparación a las anteriores, siendo esta última (la evaporización) la que obtuvo un error no tan aceptable, y por último con la variable de la precipitación notablemente se puede contemplar que el modelo no tuvo éxito debido que el patrón de la misma está compuesta por valores y picos demasiados inconsistentes lo cual dificultó seguir un patrón claro durante la etapa de aprendizaje.

Tabla 3.9. Precisión del modelo con los datos del sitio web Power Data Access Viewer

Variables	MAPE	Exactitud
Humedad	6,25%	93,75%
Temperatura Máxima	5,46%	94,54%
Temperatura Mínima	3,04%	96,96%
Velocidad del viento	17,96%	82,04%
Precipitación	75,07%	24,93%

Fuente: Los autores

Con el segundo conjunto de datos empleados (**tabla 3.9**), la humedad, la temperatura máxima y la temperatura mínima fueron las que obtuvieron valores de error netamente aceptables, siendo esta última la que obtuvo un mejor desempeño, no obstante, el modelo con la velocidad del viento también logró tener un buen desempeño, en cambio, con la precipitación notamos que de igual manera el modelo no pudo lograr aprender el patrón de la serie con esta variable, lo cual, para la predicción de esta no es factible debido que su tasa de error es alta teniendo como consecuencia menor exactitud en el pronóstico.

Por último, el modelo muestra el comportamiento de las variables para los próximos 15 días. No obstante, la predicción está basada en el aprendizaje sobre los datos disponibles y para aquellas variables con las que el modelo obtuvo una exactitud aceptables más eficiente y preciso es el pronóstico del clima.

Tabla 3.10. Pronóstico del clima con los datos de la estación meteorológica de la ESPAM – MFL para los próximos 15 días

Humedad	Temperatura máxima	Temperatura mínima	Temperatura Ambiente	Evaporización	Precipitación	Velocidad del viento
86.04384	30.623337	21.156094	25.638966	3.606012	0.3646367	17.01456
84.648285	30.851374	21.308828	25.895372	3.6067553	0.36569804	16.609482
84.81655	30.562162	21.494062	26.207157	3.6439214	0.37220716	17.304634
81.69514	31.404655	22.520338	26.258595	3.690972	0.3827999	16.870508
84.89231	30.397385	21.67151	25.87897	3.6697228	0.3780679	17.247679
84.973206	30.459	21.050327	25.244278	3.605305	0.36640608	17.22024
82.933014	30.53655	21.829487	26.50726	3.6763139	0.3799072	18.089993
85.771736	30.545925	21.423437	25.728306	3.6378555	0.36906487	17.34368
84.66398	30.818813	21.669044	25.620157	3.6440756	0.3715549	16.68736
82.686195	30.999166	22.28061	26.20873	3.6908488	0.3819603	17.953506
80.49962	31.462748	22.634562	26.379526	3.6987624	0.38368252	16.607847
81.93296	31.162024	21.98343	26.144648	3.6553044	0.37686992	16.703606
80.10362	31.465477	22.60913	26.595015	3.6964588	0.38363266	17.724098
82.87853	31.211626	21.384706	25.174076	3.591615	0.36513585	16.746447
82.80539	30.811935	21.784779	25.882343	3.6553607	0.37604108	17.266958

Fuente: Los autores

Tabla 3.11. Pronóstico del clima con los datos del sitio web Power Data Acces Viewer para los próximos 15 días

Humedad	Temperatura Máxima	Temperatura Mínima	Precipitación	Velocidad del viento
62.99002	31.617588	20.455435	0.7958714	2.1007159
61.95956	31.968414	20.598814	0.9802156	2.1011016
63.557762	30.631088	20.737999	0.7734057	2.1351504
70.635605	30.921518	21.493288	1.5224035	2.180726
60.50384	29.671837	20.876926	0.6756281	2.1589262
61.62454	31.32239	20.35404	0.682862	2.1010585
65.231995	29.764524	21.019402	0.7767331	2.166031
64.02036	30.750721	20.677204	0.75993294	2.128382
62.494354	31.020191	20.894346	0.97175735	2.1338196
69.442535	30.101648	21.365189	1.136692	2.179291
71.84482	30.863667	21.56868	1.5661746	2.188046
66.479	31.357372	21.11919	1.2991712	2.1451733

77.62404	30.94014	21.549515	1.5678552	2.186102
67.67456	32.95935	20.647926	1.3314499	2.087268
63.64924	30.725462	20.988016	0.97477716	2.1448224

Fuente: Los autores

Es conveniente acotar que los nuevos valores generados por el modelo (**tabla 3.10**) y (**tabla 3.11**) son a partir del último dato de la serie de tiempo de cada una de las variables procesadas, es decir, estos 15 días pronosticados a futuros son pertenecientes al mes de noviembre del 2019 ya que los datos recopilados fueron a partir del 1 septiembre del 2010 hasta el 30 junio del 2019. Para finalizar con lo acotado se graficaron estos nuevos valores para poder visualizar de mejor manera el comportamiento de las variables meteorológicas de ambos conjuntos de datos (**Anexo 6A y 6B**).

CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES

4.1. CONCLUSIONES

- La revisión sistemática facilitó el proceso de sintetizar los contenidos de múltiples investigaciones, dado su preciso protocolo de realización, agilizó el proceso de obtención de evidencias en fuentes de información de alto impacto relacionadas al tema de investigación.
- Se pudo determinar que la mayoría de investigaciones hicieron uso de la red neuronal recurrente siguiendo una estructura del algoritmo LSTM siendo el modelo más apropiado para trabajar con datos de orden cronológico.
- Se logró interpretar con el coeficiente de correlación de Pearson la relación estadística entre dos variables continuas, denotándose que los elementos de los datasets en su mayoría tenían comportamientos no lineales.
- El modelo obtuvo un mejor desempeño con las variables: humedad, temperatura máxima y la temperatura mínima; la cuales alcanzaron valores mínimos de error, obteniendo una exactitud entre los valores reales y predichos del 89.27%, 92%, y 90.61% con los datos de estación meteorológica, de igual manera las mismas empleando segundo dataset consiguieron un 93.75%, 94.54%, y 96.96% de exactitud.

4.2. RECOMENDACIONES

- En la fase de revisión bibliográfica, es preferible que las investigaciones en su mayoría sean de revistas de alto impacto y en inglés, además manejar un nivel experto de las bases de datos científicas para un filtrado eficiente de la información.
- Tener en cuenta que las técnicas empleadas en la inteligencia artificial, no todas se ajustan de mejor manera ante ciertos escenarios, por ello, al momento de evaluar modelos computacionales y algoritmos es fundamental investigar si constan antecedentes relacionados con el área a trabajar, debido que esto permite corroborar si existe un buen funcionamiento de los mismos con altos índices de efectividad en cuanto a predicciones se refiere.
- Para estudiar comportamientos de los datos climáticos se requiere observaciones de un buen número de años con el propósito de tener un mejor análisis de las tendencias y las variaciones del clima.
- Se recomienda entrenar continuamente el modelo con nuevos datos para ajustar el pronóstico y minimizar los errores de predicción.
- Para futuras investigaciones es recomendable instalar una versión de Python 3.7.5 o superior debido que las librerías para proyectos de inteligencia artificial constantemente están en soporte y en versiones anteriores dejan de ser compatibles por las nuevas actualizaciones existentes.

BIBLIOGRAFÍA

- Administración Nacional de la Aeronáutica y del Espacio [NASA]. (13 de julio de 2020). Visor de acceso de datos. https://power.larc.nasa.gov/data-accessviewer/?fbclid=IwAR2ec09MYyCbHvGOLw_HWtWrwhnjue89Q7X
- Ali, S.A., Ahmad, A. (2019). Forecasting MSW generation using artificial neural network time series model: a study from metropolitan city. *SN Appl. Sci.* 1, 1338. <https://doi.org/10.1007/s42452-019-1382-7>
- Azad, S., Debnath, S., & Rajeevan. M. (2015). Analysing Predictability in Indian Monsoon Rainfall: A Data Analytic Approach. 2, 717–727. DOI: <https://doi.org/10.1007/s40710-015-0108-0XGvAKEY-5zkSeZd3G96AKQIo>
- Carrión, M., Gutiérrez, G., & Celi, J. (2018). Modelado y Predicción del Fenómeno El Niño en Piura, Perú mediante Redes Neuronales Artificiales usando Matlab. *Scielo*, 29(4), 303 - 304. doi: <http://dx.doi.org/10.4067/S0718-07642018000400303>.
- Carvajal, T., Viacrucis, K., Hernández, L., Amalin , D., & Watanabe. (2018). Machine learning methods reveal the temporal pattern of dengue incidence using meteorological factors in metropolitan Manila, Philippines. 18, 183. DOI: <https://doi.org/10.1186/s12879-018-3066-0>
- Cazalla, A. (2015). Análisis de la evolución del desempleo en España como serie temporal. Consultado el 5 de julio del 2020. <http://tauja.ujaen.es/bitstream/10953.1/4405/1/TFG-Quesada-Cazalla%2CAna.pdf>
- Covarrubias, R., Fuentes, A., Iriarte, A., González, M., Zamora, L., & González, A. (2017). Sistema multiagente para la predicción de clima para usos agrícolas. *RIDTEC*, 13(1), 17 - 19.
- Egüez, G. (2020). Análisis del desempeño de redes neuronales artificiales en la reconstrucción de datos pluviométricos de la ciudad de Quito. Consultado el 5 de julio del 2020. DOI: <https://repositorio.uasb.edu.ec/handle/10644/7461>

- ESPAM MFL (Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López). 2019. Estatuto de la Escuela Superior Politécnica Agropecuaria de Manabí MFL, EC. p 4.
- Fernández, H., King, K. & Enríquez, C. (2019). Revisiones Sistemáticas Exploratorias como metodología para la síntesis del conocimiento científico. *Enfermería Universitaria*, 17(1), 89 - 90. doi: <https://doi.org/10.22201/eneo.23958421e.2020.1.697>
- Fossati, J. (2019). Diseño de redes neuronales inteligentes para la realización de pronósticos en micro-redes eléctricas. *Dialnet*, 17, 1-13.
- Fuentes, A., Sierra, M. & Morfa, Y. (2020). Corrección del pronóstico cuantitativo de la precipitación mediante el uso de redes neuronales. *Insmet*, 26(3), 2-27.
- García, E. (2019). Evaluación del potencial de las redes neuronales profundas para la predicción de la temperatura superficial del agua del mar. Consultado el 5 de julio del 2020. <https://repositorio.unican.es/xmlui/handle/10902/17865>
- González, J., Tudurí, J., & Rul. G. (2017). Análisis de Series Temporales Usando Redes Neuronales Recurrentes. Consultado el 5 de julio del 2020. <https://www.apsl.net/blog/2017/06/14/analisis-de-series-temporales-usando-redes-neuronales-recurrentes/>
- Guevara, R. (2016). El estado del arte en la investigación: ¿Análisis de los conocimientos acumulados o indagación por nuevos sentidos? *Revista Folios*, (44). 166 - 167.
- Infryanty, H., Yulianti, P., Indra M., Indra, K., & Marzuki, S. (2020). Relative humidity prediction based on a Short-Term Memory Network. *Researchgate*, (1). 2-5. DOI:10.1063/5.0003171
- Jiménez, M., Gutiérrez, J., & Pinzón. J. (2018). Modelado y Predicción del Fenómeno El Niño en Piura, Perú mediante Redes Neuronales Artificiales usando Matlab. *Scielo*, 29(4), 1-20.
- López, K. (2019). Predicción del cambio climático con Naive Bayes. Consultado el 5 de julio del 2020.

https://repositorio.upeu.edu.pe/bitstream/handle/UPEU/2818/Kenyi_Trabajo_Brachiller_2019.pdf?sequence=1&isAllowed=y

- López, M. La importancia de la meteorología como ciencia. (2017). Consultado el 16 de julio del 2020. <http://www.cienciamx.com/index.php/ciencia/ambiente/14721-importancia-meteorologia-como-ciencia>
- Luque, J., González, C., Gourdji, S., Manson, D., Obando, D., Mesa, J., & Prager, S. (2016). Impactos socioeconómicos del cambio climático en América Latina y el Caribe: 2020-2045. *Dialnet*, 13(78), 1- 17. doi: <https://doi.org/10.11144/Javeriana.cdr13-78.iscc>
- Riabani, F., García, W., & Herrera, A. (2016). Sistema de inteligencia artificial para la predicción temprana de heladas meteorológicas. *Scielo*, 7(4), 483-485.
- Ramírez, M., Benavídes, C., & Guada. C. (2018). Redes neuronales en la predicción de micro-clima Zona de estudio La Hechicera, Mérida-Venezuela. *UNAM*, 11(2), 47-61.
- Rodríguez, C. (2018). La humedad en la atmósfera: Bases físicas, instrumentos y aplicaciones. [En línea]. Available: http://ww.ucoj.mx/content/publicacionesenlinea/adjuntos/La-humedad-en-la-atmosfera_466.pdf. [Último acceso: 10 Agosto 2020].
- Rosales, M., Mora, C. & Guada, C. (2017). Redes neuronales en la predicción de micro-clima, Zona de estudio La Hechicera, Mérida-Venezuela. *Dialnet*, 11(2), 47- 49.
- Montesdeoca, B. (2016). Estudios de predicción en Series temporales de datos Meteorológicos utilizando Redes neuronales. Consultado el 5 de julio del 2020. https://accedacris.ulpgc.es/bitstream/10553/18829/1/0728348_00000_0000.pdf
- Moreno, B., Muñoz, M., Cuellar. J., Domancic, S., & Villanueva, J. (2018). Revisiones Sistemáticas: definición y nociones básicas. *Scielo*, 11(3), 185. DOI: <http://dx.doi.org/10.4067/S0719-01072018000300184>

- Olguín, G., Ramírez, S., & Morán, L. (2020). Predicción de lluvias máximas para la república mexicana mediante modelos probabilísticos no estacionarios. *TCA*, 11(4), 180.
- Páramo, P. (2020). Cómo elaborar una revisión sistemática. *Researchgate*, 3-4. DOI: 10.13140/RG.2.2.31465.85608
- Poornima, S. & Pushpalatha. M. (2019). Prediction of Rainfall Using Intensified LSTM Based Recurrent Neural Network with Weighted Linear Units. *Researchgate*, 10(11), 668. DOI: https://www.researchgate.net/publication/336934533_Prediction_of_Rainfall_Using_Intensified_LSTM_Based_Recurrent_Neural_Network_with_Weighted_Linear_Units
- Polo, D. M. (2015). Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo. *Scielo*, 91-92.
- PEDI (Plan E. de D. Institucional). 2017. Plan Estratégico de Desarrollo Institucional 2017-2021. 1 ed. Calceta-Manabí, EC. p 30.
- Sandoval, L. J. (2018). Algoritmos de aprendizaje automático para análisis y predicción de datos. *ITCA*, 1(1). 40 - 43.
- Selva, G. J. (2016). Reflexiones sobre los efectos del cambio climático en la agricultura de Bolivia. *Scielo*, 7(2), 112 - 114.
- Shi, B., Lin, S., Tan, Q. et al. Inference and prediction of malaria transmission dynamics using time series data. *Infect Dis Poverty* 9, 95 (2020). <https://doi.org/10.1186/s40249-020-00696->
- Springer link. (2020). Título, Resumen y Palabras Clave. Consultado, 31 de agosto del 2020. <https://www.springer.com/la/authors-editors/tutoriales-de-autores-y-revisores/writing-a-journal-manuscript/title-abstract-and-keywords/12022898>
- Velásquez, F. (2019). Pronóstico de precipitación sobre la cuenca aportante al embalse “La Esperanza” aplicando modelo climático HadCM3. *Rev. del Instituto de Investigación FIGMMG-UNMSM*, 22(43), 30 - 31. doi: <https://doi.org/10.15381/iigeo.v22i43.16683>

ANEXOS

ANEXO 1. DATOS EXTRAÍDOS DE LOS ARTÍCULOS SELECCIONADOS

Año	Autor(es)	Título	Descripción	Modelo	Algoritmo	Variables	Efectividad	Métrica	Herramienta
2015	Sarita Azad, Shoubhik Debnath, M. Rajeevan	Analysing Predictability in Indian Monsoon Rainfall: A Data Analytic Approach	En el presente documento se examinan los datos mensuales y anuales para analizar la previsibilidad en la India las lluvias del monzón. La estructura periódica en los datos de las series temporales se extrae usando ondas y la parte aleatoria residual se modela por separado utilizando redes neuronales artificiales (RNA). Aunque las técnicas híbridas basadas en redes neuronales y ondas se han aplicado ampliamente en los últimos años, el enfoque actual no ha sido investigado hasta ahora.(Azad, Debnath & Rajeevan, 2015).	Red Neuronal Perceptrón Multicapa	Backpropagation	Precipitación	93 %	Error cuadrático medio	Matlab
2016	Franklin Riaban, Willman Garcia, Johnny Herrera	Sistema de inteligencia artificial para la predicción temprana de heladas meteorológicas	Este estudio propone crear una máquina de aprendizaje extremo (ELM) utilizando el algoritmo propuesto por Huang sobre una red neuronal con propagación hacia adelante, como base para la predicción temprana de heladas meteorológicas.(Riaban, Garcia & Herrera, 2016).	Red Neuronal Feedforward	Backpropagation	Temperatura, Radiación Solar, Viento, Humedad, Precipitación.	90%	Error cuadrático medio	Python
2016	Besay Montesdeoca Santana	Estudios de predicción en Series temporales de datos Meteorológicos utilizando Redes neuronales	El objetivo de este trabajo es presentar otros dos modelos de predicción, basados en una serie de arquitecturas pertenecientes al aprendizaje automático y al aprendizaje profundo. Concretamente se usarán como modelos de predicción diferentes arquitecturas de redes neuronales artificiales, tales como redes neuronales Feedforward y redes LSTM.(Montesdeoca, 2016).	Red Neuronal Feedforward	Backpropagation	Velocidad del viento	95.5%	Error cuadrático medio	Python

2017	J. C. González-Avella, J. M. Tudurí, and G. Rul-Ian	Análisis de Series Temporales Usando Redes Neuronales Recurrentes	En este artículo se introduce el uso de Redes Neuronales Recurrentes (RNN) como nuevo enfoque para tratar el problema del análisis y predicción de series temporales. Como casos de estudio y para demostrar el grado de éxito del uso de RNN en este contexto, aplicamos este enfoque al estudio del consumo eléctrico en la población de Soller (Mallorca) y en el estudio del consumo eléctrico en la isla de Tenerife. (González, Tudurí & Ián, 2017).	Redes Neuronales Recurrentes	LSTM	Temperatura Consumo eléctrico	93%	Error cuadrático medio	Python
2018	Misael Ramírez Cesar Benavídes Carlos Guada	Redes neuronales en la predicción de micro-clima Zona de estudio La Hechicera, Mérida-Venezuela	Se desarrolló una Red Neuronal Artificial con capacidad para realizar predicciones climáticas a corto plazo, entrenada con datos a intervalos de 15 min durante 454 días, de una estación climatológica ubicada en Mérida. (Ramírez, Benavídes & Guada, 2018).	Red Neuronal Perceptrón Multicapa	Backpropagation	Radiancia Temperatura Humedad Velocidad del viento	72%	Error cuadrático medio	No especifica
2018	Thaddeus Carvajal, Katherine Viacrusis, Lara Fides T. Hernández Howell, Divina M. Amalin and Kozo Watanabe	Machine learning methods reveal the temporal pattern of dengue incidence using meteorological factors in metropolitan Manila, Philippines	Se plantea la cuestión de si cuál de las técnicas sería robusta y fiable, tiene como objetivo para comparar la exactitud de la predicción del patrón temporal de la incidencia del dengue en el área metropolitana de Manila como influido por factores meteorológicos a partir de cuatro técnicas de modelización, a) Modelización aditiva general, b) Autorregresiva estacional Promedio móvil integrado con variables exógenas c) Bosque aleatorio y d) Impulso de gradiente. (Carvajal, Viacrusis, Lara, Hernández, Divina, Amalin, Watanabe, 2018).	ARIMA	Autoregressive Integrated Moving Average	Precipitaciones, Humedad, Relativa, Temperatura mínima, Temperatura promedio, Temperatura máxima, La velocidad del viento, Dirección mínima del viento, Dirección máxima del viento	80%	Error cuadrático medio	No especifica

2018	Miguel Jiménez, Flabio Gutiérrez, Jorge Pinzón	Modelado y Predicción del Fenómeno El Niño en Piura, Perú mediante Redes Neuronales Artificiales usando Matlab	Se aplicaron redes neuronales artificiales a los datos climáticos de precipitación, temperaturas superficiales de mar en diferentes zonas calificadas como Niño y la velocidad de los vientos alisios con el fin de modelar y predecir el fenómeno El Niño, con seis meses de anticipación a la presencia del mismo.(Jiménez, Gutiérrez & Pinzón, 2018).	Red Neuronal Perceptrón Multicapa	Backpropagation	Temperaturas, Velocidad del Viento, Precipitación	94.8%	Error cuadrático medio	Matlab
2019	Juan Pablo Fossati	Diseño de redes neuronales inteligentes para la realización de pronósticos en micro-redes eléctricas	Conocer de antemano los perfiles de demanda y de potencia generada por las fuentes renovables constituye un aspecto esencial para la optimización de la operación de las redes eléctricas. En el caso particular de las micro-redes dicho aspecto cobra aún más importancia ya que en general un alto porcentaje de la energía generada proviene de fuentes renovables. A esto debe sumársele el hecho de que debido a un efecto de escala los parámetros a pronosticar están sometidos a una gran variabilidad. (Fossati, 2019).	Red Neuronal Feedforward	Backpropagation	Temperatura, velocidad del viento, humedad relativa, nubosidad	86%	Error cuadrático medio	No especifica

2019	Kenyi Simons López Azaña	Predicción del cambio climático con naive bayes	El análisis fue basado en una data set de 1800 registros que fueron clasificados con su variable temperatura y humedad donde 80% de la data fue utilizado para el entrenamiento y 20% para la prueba donde el error cuadrado para nuestro algoritmo fue de 0.22. También se utilizaron líneas temporales ARIMA para visualizar como seguirá la temperatura, la humedad y la precipitación en un futuro.(López, 2019).	Arima	Naive Bayes y SVM	Temperatura, Humedad, Velocidad del viento, visibilidad y presión	Naive Bayes 87% SVM 67%	Error Cuadrático Medio	Python
2019	S. Poornima, M. Pushpalatha	Prediction of Rainfall Using Intensified LSTM Based Recurrent Neural Network with Weighted Linear Units	Este artículo presenta la Red Neural Recurrente (RNN) basada en la Memoria Intensificada a Corto Plazo (LSTM) para predecir la lluvia. La red neuronal se entrena y prueba utilizando un conjunto de datos estándar de lluvia. La red capacitada producirá el atributo predicho de lluvia.(Poornima & Pushpalatha, 2019).	Red neuronal recurrente	LSTM	Temperatura y velocidad del viento	70%	Error cuadrático medio	Python

2019	Esther García Fernández	Evaluación del potencial de las redes neuronales profundas para la predicción de la temperatura superficial del agua del mar	Muestra que en los últimos años los modelos de redes neuronales han resurgido y están demostrando sus capacidades en multitud de campos y la meteorología no podía ser excluida. Gracias a sus arquitecturas tan versátiles y altamente no lineales se convierten en una herramienta útil capaz de realizar predicciones con gran exactitud. Arquitecturas modernas como las redes LSTM nos permiten introducir dependencias temporales y abordar con éxito problemas de predicción de series temporales. (García. 2019).	Red neuronal recurrente	LSTM	Temperatura	85%	Error cuadrático medio	no especifica
2020	Benyun Shi, Shan Lin, Qi Tan, Jie Cao, Xiaohong Zhou, Shang Xia5, Xiao Nong Zhou and Jiming Liu	Inference and prediction of malaria transmission dynamics using time series data	El análisis de correlación de Spearman demostró que la lluvia y La humedad jugó un papel en la transmisión del dengue con una eficiencia de correlación igual a 0,396 y 0,388, respectivamente. ANN mostró que la precipitación era el factor más crucial. El modelo de regresión multivariado de Poisson de series de tiempo reveló que el aumento del 1% de las precipitaciones correspondió a un aumento del 3,3% en los casos de dengue en Bangkok.(Shi, B., Lin, S., Tan, Q. et al, 2020).	ARIMA	Autoregressive Integrated Moving Average	Temperatura y precipitaciones	76,09%	Error cuadrático medio	Python

2020	A. Fuentes, M. Sierra, Y. Morfa	Corrección del pronóstico cuantitativo de la precipitación mediante el uso de redes neuronales	Se propone un modelo de redes neuronales como una técnica eficaz para la corrección del pronóstico cuantitativo de precipitación brindado por el modelo WRF. Para ello se emplea un Perceptrón Multi-Capa. Se logró la corrección del pronóstico cuantitativo de la precipitación en las estaciones analizadas, siendo más significativa la mejoría para la estación de Montaña y en los casos en los que el WRF sobreestima el acumulado de precipitación.(Fuentes, Sierra & Morfa, 2020).	Red Neuronal Perceptrón Multicapa	Backpropagation	Temperatura, Presión, Humedad, Precipitación	80%	Error Cuadrático Medio	Python
2020	Marlyna Infryanty Hutapea, Yolanda Yulianti Pratiwi, Indra M. Sarkis, Indra Kelana Jaya y Marzuki Sinambela	Relative humidity prediction based on a short-term memory network.	El objetivo principal de este artículo es evaluar el rendimiento del modelo de predicción de la humedad relativa (RH) base de memoria a corto plazo (LSTM) propuesto. La teoría del aprendizaje de la física computacional es un subcampo de la inteligencia artificial. En este artículo, utilizamos. (Infryanty, Yulianti, Sarkis, Kelana & Sinambela, 2020).	Red neuronal recurrente	LSTM	humedad relativa	98%	Error cuadrático medio	no especifica

2020	Gustavo Ricardo Egüez Dávila	Análisis del desempeño de redes neuronales artificiales en la reconstrucción de datos pluviométricos de la ciudad de Quito	En este artículo se detallan las observaciones y aportes que se desprenden del trabajo de generación de datos aproximados de lluvia a través del uso de redes neuronales. Al final de esta sección se propondrá posibles trabajos, que, a partir de este documento, puedan incrementar el conocimiento sobre el uso de redes neuronales para la reconstrucción de datos y determinación de impactos del cambio climático.(Egüez, 2020).	Red neuronal recurrente	LSTM	la radiación solar y el viento	70%	Error cuadrático medio	Python
2020	Sk Ajim Ali, Ateeque Ahmad	Pronosticando la generación de MSW usando el tiempo de la red neural artificial modelo de serie: un estudio de la ciudad metropolitana	El objetivo principal de este estudio es aplicar el modelo de series temporales de la RNA a lo largo de con la técnica autorregresiva para predecir la generación mensual de residuos sólidos en Calcuta. Para ello, los datos relacionados con la generación mensual de residuos sólidos fueron recogida desde 2010 hasta 2017. Los datos totales de 96 meses se dividieron en tres categorías, es decir, 70%, 15% y 15% para entrenamiento, validación y pruebas, respectivamente. El modelo fue evaluado en base a sobre el valor de rendimiento del error cuadrado medio, el error cuadrado medio de la raíz y el coeficiente de regresión.(Ali & Ahmad, 2020).	Red Neuronal Feedforward	Backpropagation	Temperatura, precipitación	92, 67 %	Error cuadrático medio	Matlab

Fuente: Los autores

**ANEXO 2(A). MEDIDAS MENSUALES DE LA ESTACIÓN METEOROLÓGICA
DE LA ESPAM – MFL.**

fecha	humedad	Temperatura máxima	Temperatura mínima	Temperatura Ambiente	Evaporación	Precipitación	Velocidad del viento
1/9/2010	77.00	33.20	19.40	25.50	6.60	0.10	761
2/9/2010	77.00	32.40	21.80	25.40	5.00	0.00	651
3/9/2010	78.00	32.40	22.40	24.70	4.60	0.00	1030
4/9/2010	82.00	27.80	20.40	23.40	1.40	0.10	450
5/9/2010	79.00	28.80	20.40	24.80	3.20	0.00	511
6/9/2010	80.00	33.40	20.80	25.20	5.90	0.00	567
7/9/2010	75.00	29.00	22.40	25.20	3.90	0.00	526
8/9/2010	78.00	29.60	22.40	25.20	4.60	0.00	773
9/9/2010	80.00	30.20	21.20	25.50	2.70	0.00	408
10/9/2010	78.00	32.60	21.80	25.50	7.10	0.00	1013
11/9/2010	82.00	28.00	22.00	24.20	3.20	0.00	597
12/9/2010	76.00	30.20	21.80	25.30	5.00	0.00	849
13/9/2010	79.00	27.00	21.60	23.90	4.00	0.00	780
14/9/2010	83.00	26.80	21.00	23.00	2.90	0.00	669
15/9/2010	84.00	26.80	20.80	23.50	2.80	0.00	430
16/9/2010	78.00	28.20	21.20	24.30	3.10	0.00	540
17/9/2010	82.00	32.20	19.20	24.70	5.30	0.00	670
18/9/2010	82.00	29.20	21.60	24.10	4.50	0.00	580
19/9/2010	78.00	32.80	21.20	25.00	7.10	0.00	735
20/9/2010	79.00	27.20	22.00	24.10	2.50	0.00	498
21/9/2010	83.00	25.60	20.80	23.70	4.60	0.00	259
22/9/2010	79.00	31.60	21.40	24.70	5.20	0.30	714
23/9/2010	80.00	29.20	21.20	24.40	3.70	0.00	449
24/9/2010	77.00	31.40	21.00	25.20	5.20	0.00	561
25/9/2010	78.00	31.80	21.00	25.10	7.60	0.00	674
26/9/2010	76.00	33.20	22.60	25.90	2.40	0.00	1044
27/9/2010	77.00	29.60	22.60	25.40	4.30	0.00	757

28/9/2010	82.00	28.20	22.00	24.40	4.60	0.00	792
29/9/2010	84.00	26.20	21.60	23.40	10.90	1.00	697
30/9/2010	84.00	24.80	20.00	22.70	1.80	0.00	438
1/10/2010	78.00	31.20	20.40	24.70	5.90	5.90	696
2/10/2010	78.00	33.40	20.20	25.00	7.10	7.10	830
3/10/2010	79.00	32.20	19.40	24.40	6.90	6.90	826
4/10/2010	80.00	27.80	21.80	24.00	3.30	3.30	674
5/10/2010	78.00	30.20	21.40	24.80	6.00	6.00	845
6/10/2010	82.00	28.00	21.60	24.30	4.80	4.80	777
7/10/2010	77.00	31.00	21.60	25.10	6.80	6.80	960
8/10/2010	76.00	27.40	21.80	24.30	3.30	3.30	600
9/10/2010	86.00	29.80	20.20	23.90	4.10	4.10	468
10/10/2010	81.00	32.20	20.20	24.70	5.90	5.90	719
11/10/2010	78.00	30.60	21.80	25.00	4.30	4.30	646
12/10/2010	76.00	31.40	20.60	25.10	6.30	6.30	558
13/10/2010	75.00	31.00	20.80	25.10	5.20	5.20	745
14/10/2010	77.00	31.00	22.20	24.90	5.80	5.80	631
15/10/2010	74.00	31.80	21.60	25.10	6.50	6.50	596
16/10/2010	76.00	32.00	19.80	24.70	6.20	6.20	670
17/10/2010	76.00	29.60	20.40	24.70	5.80	5.80	755
18/10/2010	74.00	31.20	21.40	25.00	5.80	5.80	803
19/10/2010	77.00	29.20	21.40	24.20	4.50	4.50	519
20/10/2010	78.00	28.60	21.60	24.50	4.40	4.40	597
21/10/2010	76.00	32.40	20.00	25.00	7.40	7.40	1133
22/10/2010	78.00	28.20	20.80	23.70	4.90	4.90	896
23/10/2010	81.00	26.20	20.80	23.10	3.00	3.00	582
24/10/2010	85.00	25.80	21.00	23.60	2.90	2.90	361
25/10/2010	81.00	27.80	19.60	24.00	3.30	3.30	413
26/10/2010	77.00	32.20	20.00	25.10	7.40	7.40	1017
27/10/2010	76.00	26.40	21.20	23.60	2.80	2.80	681
28/10/2010	84.00	30.00	20.20	23.30	4.00	4.00	608
29/10/2010	85.00	25.80	21.00	22.70	2.60	2.60	630
30/10/2010	79.00	29.60	20.00	23.20	5.40	5.40	1036

31/10/2010	85.00	27.20	19.80	22.90	1.60	1.60	493
1/11/2010	81.00	28.20	20.20	23.00	4.60	0.00	29.8
2/11/2010	88.00	24.80	19.40	21.60	3.20	0.00	36.9
3/11/2010	85.00	23.60	19.20	21.50	2.30	0.00	29.4
4/11/2010	78.00	30.20	19.60	23.30	4.40	0.00	25.3
5/11/2010	79.00	28.80	20.00	23.20	5.10	0.00	28.9
6/11/2010	81.00	30.20	20.00	23.80	5.30	0.00	30.7
7/11/2010	77.00	31.40	20.90	24.50	5.10	0.00	24.8
8/11/2010	79.00	30.00	19.00	24.00	7.20	0.00	31.6
9/11/2010	75.00	33.40	19.20	24.40	4.90	0.00	19.4
10/11/2010	77.00	29.40	20.60	24.50	5.30	0.00	21.7
11/11/2010	76.00	30.40	20.80	24.30	5.40	3.00	27.7
12/11/2010	84.00	29.80	20.60	23.60	3.60	0.00	20.4
13/11/2010	83.00	27.40	20.60	23.90	2.60	0.00	14
14/11/2010	85.00	28.40	22.20	24.10	3.10	0.50	28.5
15/11/2010	84.00	26.80	21.20	24.00	1.50	0.00	18
16/11/2010	85.00	26.40	21.80	23.50	1.70	0.00	11.9
17/11/2010	79.00	31.00	20.80	25.50	1.90	0.10	24
18/11/2010	81.00	28.60	21.20	24.30	3.70	0.00	26.4
19/11/2010	76.00	28.80	22.00	25.10	4.70	0.00	23.6
20/11/2010	75.00	30.60	21.20	25.00	4.50	0.00	26
21/11/2010	75.00	32.80	22.00	26.20	5.30	0.00	26.5
22/11/2010	80.00	25.20	21.80	24.00	2.60	0.00	16.9
23/11/2010	78.00	30.20	18.80	24.50	3.70	0.00	22.3
24/11/2010	81.00	28.60	21.20	24.40	4.00	0.00	14
25/11/2010	78.00	29.40	18.40	24.30	3.30	0.00	14.8
26/11/2010	82.00	28.20	20.20	24.10	2.80	0.00	16.3
27/11/2010	81.00	27.80	22.00	24.60	3.20	0.00	14.8
28/11/2010	81.00	30.20	20.40	23.90	4.50	0.00	31.9
29/11/2010	78.00	29.80	20.20	23.80	5.30	0.00	36.6
30/11/2010	77.00	30.20	21.00	24.30	4.70	0.00	23.6

ANEXO 2(B). INFORME - POWER DATA ACCESS VIEWER

El propósito de este informe es para exponer los pasos a seguir para la obtención de datos meteorológicos de una localidad o ciudad. Primero Ingresamos al enlace: <https://power.larc.nasa.gov/data-access-viewer/>, aparece la ventana de inicio del aplicativo Power Data Acces Viewer de la Administración Nacional de la Aeronáutica y del Espacio más conocida como NASA (National Aeronautics and Space Administration)




FIGURA 1. Power Data Access Viewer - Ventana de Inicio (NASA, 2020).

En el sitio existen tres tipos de comunidades que disponen de registros relacionados a cada de estas, la primera comunidad se denomina energía renovable, que dispone datos solares y eólicos, la segunda comunidad se denomina edificios sostenibles, que proporciona parámetros amigables con la industria de edificios, y por último la comunidad de agro-climatología, seleccionamos este último ya que dispone de datos meteorológicos para el estudio de diversos factores climáticos, de estas se pueden seleccionar datos diarios, mensuales y anuales, para los efectos del presente trabajo seleccionamos los datos diarios.




FIGURA 2. Especificaciones de para la obtención de los datos (NASA, 2020).

Luego para obtener los datos meteorológicos se debe elegir la localidad a la cual se requiera dicha información, esto se lo realiza a través de la longitud y latitud de la misma, y con ello extraer los registros históricos. En efecto, los autores eligieron como localidad la ciudad de Calceta perteneciente al cantón Bolívar de la provincia de Manabí ubicándose con longitud -0.9092 y latitud -79.9563.



FIGURA 3. Selección de la localidad (NASA, 2020)

Posteriormente, se seleccionaron el rango del tiempo que se desean obtener los datos especificando la fecha de inicio y la fecha final, en este trabajo de titulación se seleccionó a partir del 1 de enero del 2010 hasta el 30 de junio del 2020.




FIGURA 4. Especificación de las fechas (NASA,2020)

Luego se seleccionó el archivo en formato CSV donde estarán almacenadas las medidas meteorológicas.



FIGURA 5. Formato del archivo (NASA,2020)

Se seleccionaron las medidas de precipitación, velocidad del viento, humedad relativa, temperatura máxima y mínima. Y damos click en el botón enviar.

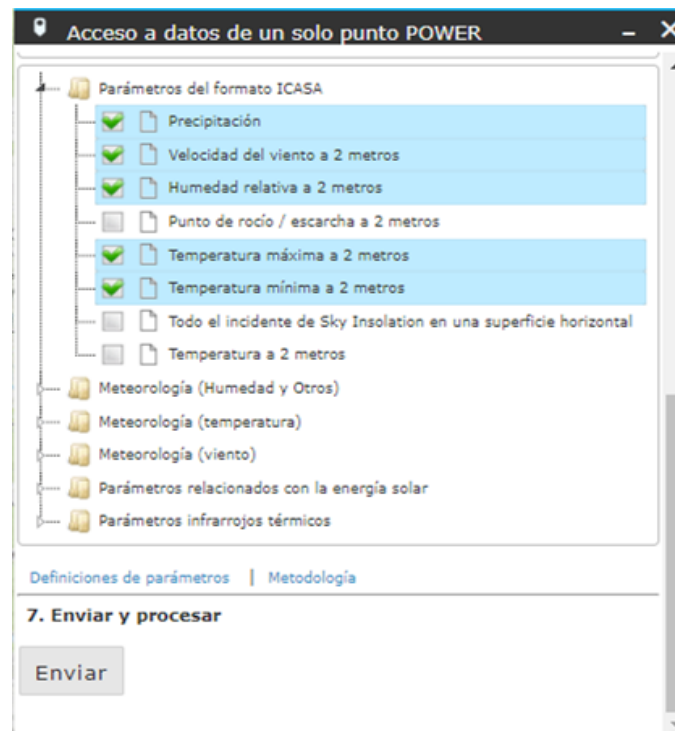


FIGURA 6. Selección de las medidas meteorológicas(NASA,2020)

Finalmente visualizamos la ventana para descargar los datos seleccionados, para ello damos click en el botón “CSV” que es el formato del archivo.

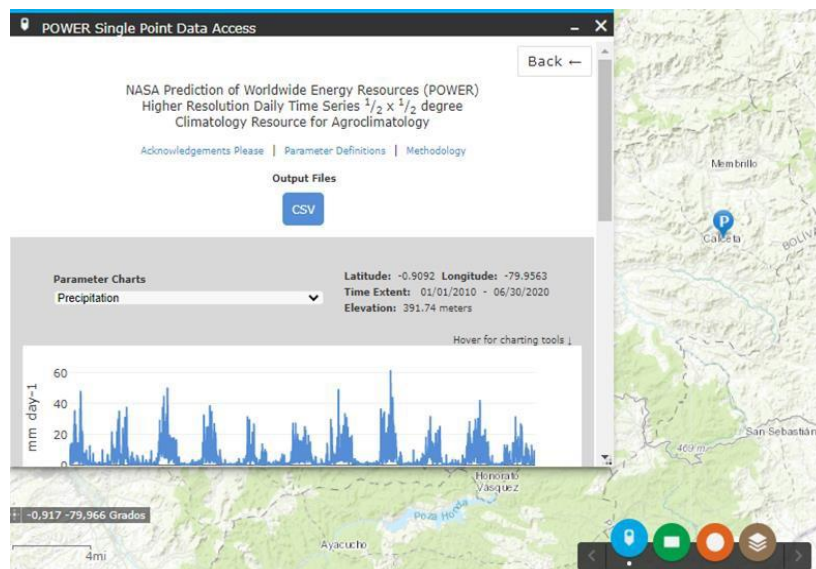


FIGURA 7. Ventana de descarga del archivo en formato CSV, (NASA, 2020)

ANEXO 2(C). MEDIDAS MENSUALES DEL VISOR DE ACCESO DE DATOS

LAT	LON	YEAR	DOY	PRECTOT	WS2M	RH2M	T2M_MAX	T2MDEW	T2M_MIN
-0.91069	-7.996.259	2010	1	0.03	2.47	60.03	33.44	17.68	20.99
-0.91069	-7.996.259	2010	2	0.00	2.50	60.25	34.13	18.02	21.21
-0.91069	-7.996.259	2010	3	0.01	2.92	59.42	34.70	18.17	21.68
-0.91069	-7.996.259	2010	4	0.86	2.68	61.85	33.17	18.26	22.10
-0.91069	-7.996.259	2010	5	0.17	2.62	67.07	32.11	19.11	21.69
-0.91069	-7.996.259	2010	6	0.00	2.54	61.94	33.71	18.76	22.23
-0.91069	-7.996.259	2010	7	0.28	2.80	66.56	33.41	19.57	22.50
-0.91069	-7.996.259	2010	8	1.66	2.76	72.94	30.13	20.08	22.40
-0.91069	-7.996.259	2010	9	0.82	2.71	69.76	32.55	19.97	21.88
-0.91069	-7.996.259	2010	10	13.38	1.97	78.49	28.53	20.46	22.13
-0.91069	-7.996.259	2010	11	6.27	2.04	82.25	27.66	20.84	22.16
-0.91069	-7.996.259	2010	12	1.25	2.06	70.78	33.08	19.94	21.37
-0.91069	-7.996.259	2010	13	4.62	2.40	76.27	31.30	20.96	21.88
-0.91069	-7.996.259	2010	14	1.10	2.64	74.26	30.81	20.32	21.88
-0.91069	-7.996.259	2010	15	0.80	2.38	68.67	32.99	19.92	21.54
-0.91069	-7.996.259	2010	16	0.36	2.32	69.88	32.37	20.02	21.93
-0.91069	-7.996.259	2010	17	7.24	2.21	69.19	33.90	20.26	21.52
-0.91069	-7.996.259	2010	18	4.06	2.20	73.70	31.49	20.63	21.70
-0.91069	-7.996.259	2010	19	9.80	2.29	76.65	31.45	21.13	21.73
-0.91069	-7.996.259	2010	20	5.38	2.13	72.66	32.97	20.96	21.65
-0.91069	-7.996.259	2010	21	3.40	2.26	73.15	33.11	21.20	22.64
-0.91069	-7.996.259	2010	22	14.28	2.34	75.80	32.05	21.28	22.32
-0.91069	-7.996.259	2010	23	13.24	1.93	79.89	29.82	21.00	21.69
-0.91069	-7.996.259	2010	24	9.12	2.12	79.58	30.00	21.09	21.83
-0.91069	-7.996.259	2010	25	3.67	2.12	77.02	31.02	21.02	21.94
-0.91069	-7.996.259	2010	26	7.24	2.24	79.46	30.20	21.09	21.93
-0.91069	-7.996.259	2010	27	8.53	2.45	81.21	30.79	21.71	22.29
-0.91069	-7.996.259	2010	28	3.69	2.61	81.07	29.62	21.17	21.92
-0.91069	-7.996.259	2010	29	2.20	2.23	79.11	30.73	21.01	21.66
-0.91069	-7.996.259	2010	30	3.25	2.19	79.00	31.37	21.45	21.95
-0.91069	-7.996.259	2010	31	1.02	2.42	77.31	31.83	21.51	22.10
-0.91069	-7.996.259	2010	32	4.29	2.39	75.91	31.85	21.33	22.23
-0.91069	-7.996.259	2010	33	0.55	2.29	75.67	31.69	21.19	21.51
-0.91069	-7.996.259	2010	34	1.45	2.34	76.56	31.66	21.25	21.71
-0.91069	-7.996.259	2010	35	0.83	1.98	75.28	32.30	21.63	22.15
-0.91069	-7.996.259	2010	36	1.32	2.48	79.94	30.65	21.77	22.93
-0.91069	-7.996.259	2010	37	7.19	1.49	82.57	27.53	20.99	21.75
-0.91069	-7.996.259	2010	38	3.71	1.65	76.67	31.46	21.28	21.88
-0.91069	-7.996.259	2010	39	12.71	1.91	82.05	29.63	21.92	22.82
-0.91069	-7.996.259	2010	40	26.63	2.58	84.64	29.22	21.93	22.29
-0.91069	-7.996.259	2010	41	15.86	1.90	87.57	27.57	21.88	22.15


-0.91069	-7.996.259	2010	42	9.07	2.00	87.10	28.38	22.16	22.18
-0.91069	-7.996.259	2010	43	8.23	2.14	88.16	27.02	21.99	22.39
-0.91069	-7.996.259	2010	44	9.43	1.65	86.06	28.01	21.86	21.92
-0.91069	-7.996.259	2010	45	13.04	1.74	83.39	30.11	22.16	22.17
-0.91069	-7.996.259	2010	46	35.31	1.91	87.17	28.61	22.33	22.42
-0.91069	-7.996.259	2010	47	20.33	1.89	88.21	27.69	22.28	21.96
-0.91069	-7.996.259	2010	48	8.32	1.67	84.12	29.80	22.41	22.29
-0.91069	-7.996.259	2010	49	1.54	1.70	82.48	30.37	22.52	22.36
-0.91069	-7.996.259	2010	50	2.80	2.30	86.00	29.16	22.66	22.87
-0.91069	-7.996.259	2010	51	5.53	2.20	83.24	30.82	22.58	22.21
-0.91069	-7.996.259	2010	52	23.00	2.46	84.75	30.13	22.90	23.00
-0.91069	-7.996.259	2010	53	15.98	1.34	89.44	26.87	22.45	22.77
-0.91069	-7.996.259	2010	54	14.76	1.51	86.01	29.13	22.39	22.27
-0.91069	-7.996.259	2010	55	26.24	1.73	87.54	28.65	22.59	22.47
-0.91069	-7.996.259	2010	56	16.99	1.26	89.99	26.94	22.52	22.47
-0.91069	-7.996.259	2010	57	16.29	1.08	83.86	28.76	22.00	22.33
-0.91069	-7.996.259	2010	58	5.02	1.79	84.54	29.57	22.22	22.02
-0.91069	-7.996.259	2010	59	5.05	1.68	84.23	29.38	22.14	22.17
-0.91069	-7.996.259	2010	60	12.20	2.07	84.50	29.51	21.94	21.89
-0.91069	-7.996.259	2010	61	2.15	1.83	84.65	28.69	21.77	21.68
-0.91069	-7.996.259	2010	62	10.61	1.83	84.80	29.31	21.84	21.36
-0.91069	-7.996.259	2010	63	10.25	1.74	85.26	29.79	22.27	21.86
-0.91069	-7.996.259	2010	64	4.46	2.04	84.36	30.15	22.47	21.99
-0.91069	-7.996.259	2010	65	13.95	2.04	85.82	29.59	22.59	22.19
-0.91069	-7.996.259	2010	66	12.43	1.95	85.08	29.42	22.25	21.81
-0.91069	-7.996.259	2010	67	1.85	2.35	86.55	29.15	22.48	22.24
-0.91069	-7.996.259	2010	68	5.04	1.96	90.26	27.33	22.66	22.80
-0.91069	-7.996.259	2010	69	4.49	1.83	87.19	28.35	22.20	21.75
-0.91069	-7.996.259	2010	70	11.11	1.55	88.49	27.44	22.23	22.30
-0.91069	-7.996.259	2010	71	14.51	1.46	88.90	27.41	22.19	22.02
-0.91069	-7.996.259	2010	72	13.00	1.42	84.87	28.57	21.92	21.81
-0.91069	-7.996.259	2010	73	2.24	1.39	83.86	29.86	22.44	22.35
-0.91069	-7.996.259	2010	74	10.02	1.97	87.11	28.51	22.50	22.54
-0.91069	-7.996.259	2010	75	2.97	1.68	84.46	29.05	21.99	21.74
-0.91069	-7.996.259	2010	76	3.49	1.95	86.18	29.04	22.18	22.09
-0.91069	-7.996.259	2010	77	7.60	1.56	83.36	29.22	21.75	21.81
-0.91069	-7.996.259	2010	78	9.77	1.84	88.09	28.42	22.67	22.34
-0.91069	-7.996.259	2010	79	4.52	1.82	89.67	27.48	22.74	22.87
-0.91069	-7.996.259	2010	80	7.45	1.96	85.72	29.46	22.28	21.83
-0.91069	-7.996.259	2010	81	7.43	1.87	87.34	27.81	22.16	22.04
-0.91069	-7.996.259	2010	82	0.18	1.59	85.33	29.73	22.41	21.61
-0.91069	-7.996.259	2010	83	10.06	1.88	85.45	29.18	22.38	22.56
-0.91069	-7.996.259	2010	84	9.74	1.90	84.81	29.23	22.00	22.02
-0.91069	-7.996.259	2010	85	6.74	1.15	83.06	28.93	21.82	22.00
-0.91069	-7.996.259	2010	86	0.79	1.82	83.79	30.48	22.66	22.31

-0.91069	-7.996.259	2010	87	2.99	1.90	84.77	29.29	22.13	22.11
-0.91069	-7.996.259	2010	88	12.06	2.14	86.16	28.99	22.21	21.91
-0.91069	-7.996.259	2010	89	28.21	1.82	89.87	27.24	22.00	21.59
-0.91069	-7.996.259	2010	90	36.57	1.42	91.72	25.75	21.95	21.64
-0.91069	-7.996.259	2010	91	21.85	1.80	89.03	28.34	22.66	21.82
-0.91069	-7.996.259	2010	92	8.38	1.75	86.38	28.67	22.05	21.92
-0.91069	-7.996.259	2010	93	4.80	1.90	87.07	28.50	22.32	21.72
-0.91069	-7.996.259	2010	94	48.00	1.81	87.02	29.54	22.48	21.82
-0.91069	-7.996.259	2010	95	43.61	1.80	89.19	28.15	22.86	22.58
-0.91069	-7.996.259	2010	96	13.57	0.95	83.29	28.93	21.80	22.06
-0.91069	-7.996.259	2010	97	11.98	1.54	87.55	28.39	22.41	21.93
-0.91069	-7.996.259	2010	98	13.07	1.74	88.07	28.39	22.46	22.16
-0.91069	-7.996.259	2010	99	23.60	1.60	88.44	27.79	22.46	22.02
-0.91069	-7.996.259	2010	100	2.50	1.62	86.71	28.74	22.30	21.67
-0.91069	-7.996.259	2010	101	14.33	1.52	90.65	27.44	22.35	22.20
-0.91069	-7.996.259	2010	102	4.58	1.96	88.10	28.60	22.27	22.10
-0.91069	-7.996.259	2010	103	2.42	1.92	86.11	28.56	21.84	21.60
-0.91069	-7.996.259	2010	104	1.10	1.68	87.80	28.61	22.25	21.70
-0.91069	-7.996.259	2010	105	4.83	1.90	90.17	27.30	22.56	22.43
-0.91069	-7.996.259	2010	106	0.65	1.92	85.72	29.02	22.13	21.89
-0.91069	-7.996.259	2010	107	2.93	1.57	85.63	29.09	22.14	22.04
-0.91069	-7.996.259	2010	108	16.45	2.03	86.84	29.31	22.54	21.81
-0.91069	-7.996.259	2010	109	21.98	1.88	88.62	27.75	22.26	22.07
-0.91069	-7.996.259	2010	110	3.15	1.78	85.17	29.39	22.22	21.77
-0.91069	-7.996.259	2010	111	0.83	1.69	86.29	28.38	22.10	21.57
-0.91069	-7.996.259	2010	112	0.48	1.86	85.32	30.16	22.57	21.89
-0.91069	-7.996.259	2010	113	0.14	2.22	84.54	29.63	22.18	21.87
-0.91069	-7.996.259	2010	114	0.55	1.95	85.50	28.83	21.73	21.43
-0.91069	-7.996.259	2010	115	1.51	2.00	85.44	28.83	21.47	20.92
-0.91069	-7.996.259	2010	116	4.30	1.27	86.04	28.28	21.73	21.10
-0.91069	-7.996.259	2010	117	4.19	1.78	86.38	29.27	22.39	21.92
-0.91069	-7.996.259	2010	118	5.61	1.60	87.90	27.93	21.82	21.78
-0.91069	-7.996.259	2010	119	1.08	1.63	85.30	28.87	21.97	21.75
-0.91069	-7.996.259	2010	120	2.22	1.82	87.93	28.29	22.25	21.96
-0.91069	-7.996.259	2010	121	1.32	1.13	84.98	28.76	22.11	22.07
-0.91069	-7.996.259	2010	122	4.79	2.09	87.69	28.25	22.31	22.10
-0.91069	-7.996.259	2010	123	6.71	1.13	86.50	28.06	21.79	21.75
-0.91069	-7.996.259	2010	124	3.12	1.28	85.10	28.46	21.73	22.12
-0.91069	-7.996.259	2010	125	7.83	1.63	86.36	28.82	22.20	22.01
-0.91069	-7.996.259	2010	126	5.83	1.70	86.80	28.18	22.06	22.07
-0.91069	-7.996.259	2010	127	0.13	1.99	84.96	29.48	22.24	22.03
-0.91069	-7.996.259	2010	128	0.48	2.03	85.47	29.40	22.43	22.32
-0.91069	-7.996.259	2010	129	0.45	2.01	85.98	29.93	22.88	22.56
-0.91069	-7.996.259	2010	130	1.27	1.84	85.72	29.33	22.62	22.66
-0.91069	-7.996.259	2010	131	0.13	2.02	81.72	31.21	22.10	21.65

ANEXO 3(A). DATA SET DE LA ESTACIÓN METEOROLÓGICA DE LA ESPAM - MFL

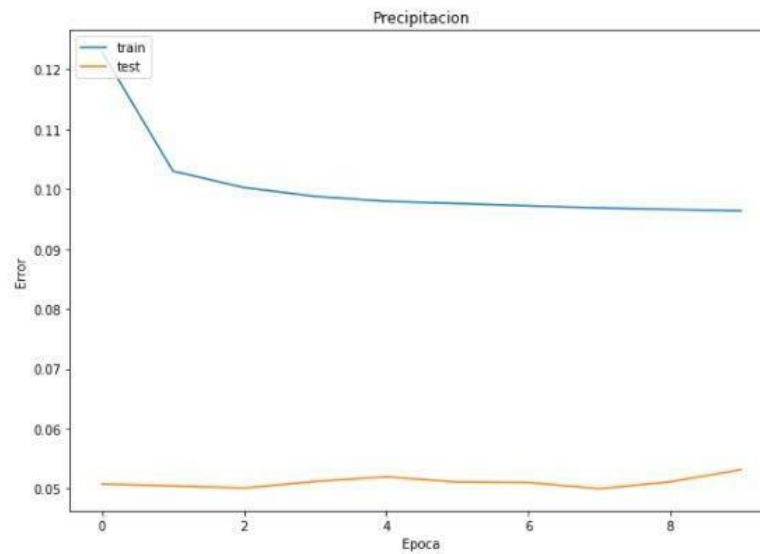
The screenshot displays the Microsoft Excel interface with the following data set:

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	fecha	humedad_rela	temp_min	temp_max	temp_ambiente	evaporacion	precipitacion	viento_km						
2	1/9/2010	77.00	33.20	19.40	25.50	6.60	0.10	761						
3	2/9/2010	77.00	32.40	21.80	25.40	5.00	0.00	651						
4	3/9/2010	78.00	32.40	22.40	24.70	4.60	0.00	1030						
5	4/9/2010	82.00	27.80	20.40	23.40	1.40	0.10	450						
6	5/9/2010	79.00	28.80	20.40	24.80	3.20	0.00	511						
7	6/9/2010	80.00	33.40	20.80	25.20	5.90	0.00	567						
8	7/9/2010	75.00	29.00	22.40	25.20	3.90	0.00	526						
9	8/9/2010	78.00	29.60	22.40	25.20	4.60	0.00	773						
10	9/9/2010	80.00	30.20	21.20	25.50	2.70	0.00	408						
11	10/9/2010	78.00	32.60	21.80	25.50	7.10	0.00	1013						
12	11/9/2010	82.00	28.00	22.00	24.20	3.20	0.00	597						
13	12/9/2010	76.00	30.20	21.80	25.30	5.00	0.00	849						
14	13/9/2010	79.00	27.00	21.60	23.90	4.00	0.00	780						
15	14/9/2010	83.00	26.80	21.00	23.00	2.90	0.00	669						
16	15/9/2010	84.00	26.80	20.80	23.50	2.80	0.00	430						
17	16/9/2010	78.00	28.20	21.20	24.30	3.10	0.00	540						
18	17/9/2010	82.00	32.20	19.20	24.70	5.30	0.00	670						

ANEXO 4(B). DISPERSIÓN DE LOS DATOS CON LA CORRELACIÓN DE PEARSON – SET_POWERDATA

ANEXO 5(A). ENTRENAMIENTO Y TESTEO CON LA RED NEURONAL FEEDFORWARD

```
In [17]: plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Precipitacion')
plt.ylabel('Error')
plt.xlabel('Epoca')
plt.legend(['train', 'test'], loc='upper left')
plt.show()
```



```
In [13]: #plt.ylim(0.12, 0.35)
plt.plot(history.history['loss'])
plt.title('loss')
plt.plot(history.history['val_loss'])
plt.title('validate loss')
plt.show()
```

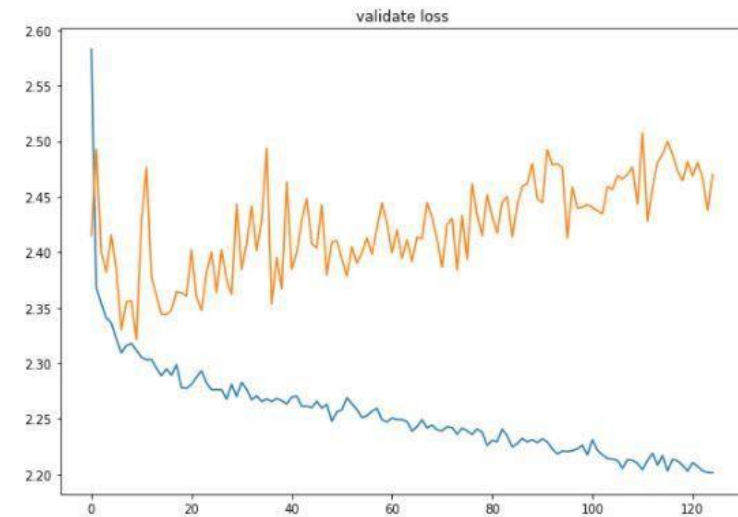


Ilustración 1. Experimentación con Epochs de 10 a 120, observamos que la predicción del modelo fue errónea (línea naranja) debido que no fue capaz de aprender la secuencia real de los datos (línea azul).

ANEXO 5(B). ENTRENAMIENTO Y TESTEO CON LA RED NEURONAL PERCEPTRON MULTICAPA

```
In [13]: #plt.ylim(0.12, 0.35)
plt.plot(history.history['loss'])
plt.title('loss')
plt.plot(history.history['val_loss'])
plt.title('validate loss')
plt.show()
```

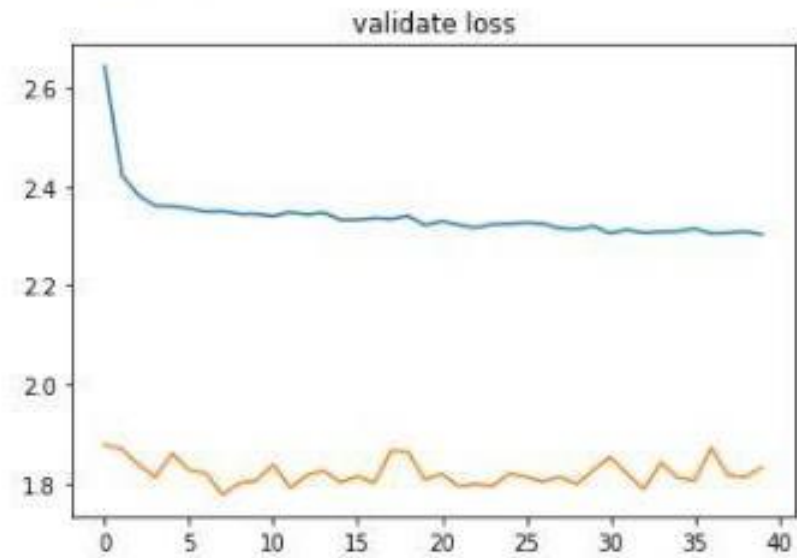









Ilustración 2. La red Perceptrón Multicapa empleando una cantidad notable de 40 Epochs no logró aproximarse (línea naranja) a la secuencia real de los datos (línea azul)

ANEXO 6(A). PREDICCIONES DE LOS PRÓXIMOS 15 DÍAS CON LOS DATOS DE LA ESTACIÓN METEOROLÓGICA DE ESPAM-MFL



ANEXO 6(B). PREDICCIONES DE LOS PRÓXIMOS 15 DÍAS CON LOS DATOS DEL SITIO WEB POWER DATA ACCESVIEWER.

