

**UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA**



TESIS

**Modelo predictivo para estimar el índice de radiación solar
ultravioleta en región Lambayeque**

**PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO ELECTRÓNICO**

ELABORADA POR:

Bach. Bustamante Ruiz, George Jason

Bach. Espinoza Gallardo Juan Carlos

ASESOR:

Mg. Ing. Oscar Uchelly Romero Cortez

ORCID:

<https://orcid.org/0000-0002-7727-7900>

**LAMBAYEQUE – PERÚ
2024**

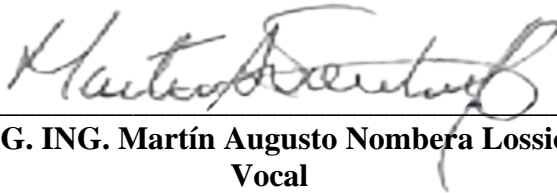
JURADOS



M.SC. ING. Frank Richard Rodríguez Chirinos
Presidente



ING. Segundo Francisco Segura Altamirano
Secretario



MG. ING. Martín Augusto Nombera Lossio
Vocal

Asesor



MG. ING. Oscar Uchelly Romero Cortez



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por **Turnitin**. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: George Jason Bustamante Ruiz
Título del ejercicio: MODELO PREDICTIVO PARA ESTIMAR EL INDICE DE RADIACI...
Título de la entrega: MODELO PREDICTIVO PARA ESTIMAR EL INDICE DE RADIACI...
Nombre del archivo: Informe_Final_-_Bustamante_Ruiz_y_Espinoza_Gallardo.docx
Tamaño del archivo: 2.33M
Total páginas: 96
Total de palabras: 12,785
Total de caracteres: 71,511
Fecha de entrega: 21-dic.-2023 04:05p. m. (UTC-0500)
Identificador de la entre... 2263839693

UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA



TESIS
"MODELO PREDICTIVO PARA ESTIMAR EL INDICE DE
RADIACIÓN SOLAR ULTRAVIOLETA EN REGIÓN
LAMBAYEQUE"

PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO ELECTRÓNICO

ELABORADA POR:

Bach. Bustamante Ruiz, George Jason

Bach. Espinoza Gallardo Juan Carlos

ASESOR:

Mg. Ing. Oscar Uccelly Romero Cortez

LAMBAYEQUE - PERÚ
2023

Ing. Oscar Uccelly Romero Cortez

MODELO PREDICTIVO PARA ESTIMAR EL INDICE DE RADIACIÓN SOLAR ULTRAVIOLETA EN REGIÓN LAMBAYEQUE

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

7%

FUENTES DE INTERNET

2%

PUBLICACIONES

6%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

Submitted to Universidad Internacional de la Rioja

Trabajo del estudiante

2%

2

repositorio.unprg.edu.pe

Fuente de Internet

1%

3

repositorio.unh.edu.pe

Fuente de Internet

1%

4

rua.ua.es

Fuente de Internet

1%

5

Submitted to Instituto Superior de Artes, Ciencias y Comunicación IACC

Trabajo del estudiante

1%

6

Submitted to consultoriadeserviciosformativos

Trabajo del estudiante

<1%

7

oa.upm.es


Fuente de Internet

<1%

8

Submitted to imfice

Trabajo del estudiante



Ing. Oscar Ucchelly Romero Cortez


CONSTANCIA DE VERIFICACIÓN DE ORIGINALIDAD
(RESOLUCIÓN N° 626-2021-CU DEL 30 DE DICIEMBRE 2021)

Yo, Oscar Uchelly Romero Cortez, usuario revisor del documento titulado **Modelo predictivo para estimar el índice de radiación solar ultravioleta en región Lambayeque**. Cuyo autor es, **Bach. Bustamante Ruiz, George Jason**, identificado con documento de identidad **71400473** y el **Bach. Espinoza Gallardo Juan Carlos**, identificado con documento de identidad **74429512**; declaro que la evaluación realizada por el programa informático ha arrojado un porcentaje de similitud de **9%**, verificable en el resumen de reporte automatizado de similitudes que se acompaña.

El suscrito analizó dicho reporte y concluyó que cada una de las coincidencias detectadas dentro del porcentaje de similitud permitido no constituyen plagio y que el documento cumple con la integridad científica y con las normas para el uso de citas y referencias establecidas en los protocolos respectivos.

Se cumple con adjuntar el Recibo Digital a efectos de la trazabilidad respectiva del proceso.

Lambayeque, 26 de diciembre del 2023



Ing. Oscar Uchelly Romero Cortez

DNI: 41812294

Asesor

(Precisar si es docente, asesor, docente investigador, administrativo u otro)

Se adjunta:

*Resumen de Reporte automatizado de similitudes

*Recibo Digital



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FISICAS Y MATEMATICAS
DECANATO

Ciudad Universitaria - Lambayeque

LICENCIADA - RESOLUCION DEL CONSEJO DIRECTIVO N° 015 -2023-SUNEDU / CD



0020



ACTA DE SUSTENTACIÓN N° 007.-2024.-D/FACFyM

Siendo las 09:15 AM del día Viernes, 26 de enero del 2024, se reunieron los miembros del jurado evaluador de la Tesis titulada:

"Modelo Predictivo para estimar el Índice de Radiación Solar Ultravioleta en Región Lambayeque"

Designados por Resolución N° 236-2023-VIRTUAL D/FACFyM de fecha 23 de marzo 2023

Con la finalidad de evaluar y calificar la sustentación de la tesis antes mencionada, conformada por los siguientes docentes:

Msc. Ing. Frank Richard Rodríguez Chirinos

Presidente

Msc. Ing. Segundo Francisco Segura Altamirano

Secretario

Mg. Ing. Martín Augusto Nombora Losrio

Vocal

La tesis fue asesorada por (el) (la) Mg. Ing. Oscar Vachelly Romero Cortez, nombrado por Resolución N° 236-2023-VIRTUAL- D/FACFyM de fecha 23 de marzo 2023

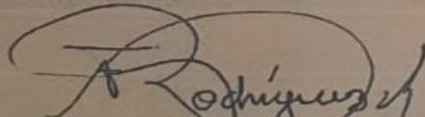
El Acto de Sustentación fue autorizado por Resolución N° 019-2024 D/FACFyM de fecha 10 de enero de 2024

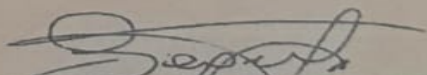
La Tesis fue presentada y sustentada por (el) (los) Bachiller (es): Bustamante Ruiz George Jason y Espinoza Gallardo Juan Carlos y tuvo una duración de 25 minutos.

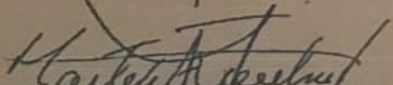
Después de la sustentación, y absueltas las preguntas y observaciones de los miembros del jurado se procedió a la calificación respectiva, otorgándole el Calificativo de dieciséis (16) en la escala vigesimal, mención (BUENO).

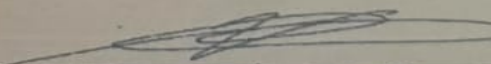
Por lo que queda(n) apto(s) para obtener el Título Profesional de Ingeniero Electrónico de acuerdo con la Ley Universitaria 30220 y la normatividad vigente de la Facultad de Ciencias Físicas y Matemáticas y la Universidad Nacional Pedro Ruiz Gallo.

Siendo las 10:10 AM se dio por concluido el presente acto académico, dándose conformidad al presente acto con la firma de los miembros del jurado.


Mg. Ing. Frank Rodríguez Chirinos
Presidente


Msc. Ing. Segundo Francisco Segura A.
Secretario


Mg. Ing. Martín A. Nombora Losrio
Vocal


Mg. Oscar Vachelly Romero Cortez
Asesor

DECLARACIÓN JURADA DE ORIGINALIDAD

Yo, Bustamante Ruiz, George Jason, junto a mi compañero Espinoza Gallardo Juan Carlos, y el Mg. Ing. Oscar Uchelly Romero Cortez, asesor de nuestro proyecto de investigación denominado “Modelo predictivo para estimar el índice de radiación solar ultravioleta en región Lambayeque”, declaramos bajo juramento que este trabajo no ha sido plagiado ni contiene datos falsos. En caso se demostrara lo contrario, asumiremos responsablemente la anulación de este informe y por ende el proceso administrativo a que hubiera lugar. Que puede conducir a la anulación del título o grado emitido como consecuencia de este informe.

Lambayeque, 23 de septiembre del 2023

Investigadores:



Bach. Bustamante Ruiz George Jason



Bach. Espinoza Gallardo Juan Carlos

Asesor:



Mg. Ing. Oscar Uchelly Romero Cortez

DEDICATORIA

*Dedico este proyecto a mis padres por su
incondicional apoyo en cada etapa de mi vida*

George Jason Bustamante Ruiz

AGRADECIMIENTOS

*Agradezco a mi familia, en especial a mis padres
por apoyarme durante todo este proceso e
impulsándome a seguir adelante para hacer realidad
todos los objetivos trazados.*

George Jason Bustamante Ruiz

DEDICATORIA

*Dedico este proyecto a mi tía Iris Magali
Gallardo Cienfuegos quien me han brindado el
apoyo moral ante cualquiera adversidad y
además el soporte material y económico para
poder concentrarme en los estudios
y nunca abandonarlo.*

Juan Carlos Espinoza Gallardo

AGRADECIMIENTOS

Les agradezco a mis padres que siempre me han brindado su apoyo incondicional para poder cumplir todos mis objetivos personales y académicos. Ellos son los que con su cariño me han impulsado siempre a perseguir mis metas y nunca abandonarlas frente a las adversidades.

Finalmente agradezco a quien lee este apartado y más de mi tesis, por permitir a mis experiencias, investigaciones y conocimiento, incurrir dentro de su repertorio de información.

Juan Carlos Espinoza Gallardo

ÍNDICE DE CONTENIDO

AGRADECIMIENTOS	VI
AGRADECIMIENTOS	VIII
CAPÍTULO I	17
1.1 DISEÑO TEÓRICO	17
1.1.1 ANTECEDENTES	17
1.2 BASES TEÓRICAS	19
1.2.1 La Radiación Solar:.....	19
1.2.2 Radiación Ultravioleta	20
1.2.3 Factores que afectan la radiación UV:	21
1.2.4 Mediciones y estimaciones de radiación UV:.....	22
1.2.5 Efectos en la Salud Humana	24
1.2.6 Efectos cutáneos de la radiación ultravioleta.....	25
1.2.7 Factores que Influyen en la Variabilidad UV	26
1.2.8 Características geográficas y climáticas de la Región Lambayeque que influyen en la radiación UV	27
1.2.9 Modelos Estadísticos	29
1.2.10 Modelos Predictivos Para El Pronóstico De La Radiación UV	35

1.2.11	Desarrollo del modelo de aprendizaje automático.....	38
1.2.12	Puesta en funcionamiento de Calculadora de UV (Pronostico - UV).....	58
CAPITULO II		60
2.1	Métodos y Materiales	60
2.1.1	Diseño de Contrastación de Hipótesis	60
2.2	Población, Muestra.....	60
2.2.1	Población.....	60
2.2.2	Muestra por conveniencia	61
2.3	Técnicas, Instrumentos, Equipos Y Materiales	61
CAPÍTULO III.....		62
3.1	RESULTADOS Y DISCUSIÓN.....	62
3.1.1	Procesos Para Pronosticar La Radiación Ultravioleta (UV)	64
3.1.2	Modelos de Aprendizaje Automático en el Pronóstico de Radiación UV	65
3.1.3	Desarrollo del modelo de aprendizaje automático.....	67
CAPÍTULO IV.....		76
4.1	CONCLUSIONES Y RECOMENDACIONES	76
4.1.1	CONCLUSIONES	76
4.1.2	RECOMENDACIONES	77
REFERENCIAS.....		79

ÍNDICE DE FIGURAS

Figura 1: Regresión lineal	30
Figura 2: Modelo Estadístico Regresión Logísticas	31
Figura 3: Modelo Estadístico de Árboles de decisión	32
Figura 4: Modelo Estadístico Random Forest	33
Figura 5: Modelo Estadístico Support Vector Machines (SVM)	34
Figura 6: Modelo Estadístico de Redes Neuronales	35
Figura 7: Diseño de Contrastación de Hipótesis	60
Figura 8: Grafica de la tendencia de la radiación entre los años 2018-2019	62
Figura 9: Radiación UV 4-10 de Febrero 2018	63
Figura 10: Radiación del 1 - 31 de Marzo del 2018	64
Figura 11: Aprendizaje Automático	65
Figura 12: Modelos de Aprendizaje Automático en el Pronóstico de Radiación UV	66
Figura 13: Pantalla GUIDE	70
Figura 14: Datos ingresados y el valor predictivo	71
Figura 15: Grafica de la radiación en el día calculado.	72
Figura 16: Cálculos múltiples de nuestro sistema	73
Figura 17: Grafica con respecto al 4 de agosto del 2024	74

Figura 18: <i>UV con respecto al 4 de mayo 2024</i>	74
Figura 19: <i>UV con respecto 4 de febrero del 2024</i>	75
Figura 20: <i>Efectos de la Radiación Infrarroja en la Piel en las personas.</i>	95
Figura 21: <i>La radiación UV puede perjudicar a los ojos y el tejido que los rodea.</i>	96

RESUMEN

La tesis Modelo Predictivo para Estimar el Índice de Radiación Solar Ultravioleta en la Región Lambayeque se centra en una investigación cuantitativa-descriptiva con enfoque aplicado. Su objetivo es desarrollar un modelo de Machine Learning preciso para estimar el índice de radiación solar ultravioleta en Lambayeque. Esto implica una revisión bibliográfica exhaustiva que guía la identificación y aplicación de técnicas de Machine Learning, culminando en un modelo robusto que puede capturar la complejidad de los datos y realizar estimaciones precisas. La disponibilidad de un conjunto de datos que incluye registros diarios y estudios previos sobre la radiación solar ultravioleta en la región es crucial para el entrenamiento y validación del modelo, mejorando su precisión. La construcción y validación de esta base de datos son pasos esenciales para garantizar un rendimiento óptimo del modelo y su capacidad para estimar con precisión en situaciones nuevas. Este modelo tiene aplicaciones en salud, actividades al aire libre, medidas de prevención de la exposición solar y el dimensionamiento de sistemas fotovoltaicos. En conjunto, esta herramienta puede generar estimaciones precisas del índice de radiación solar ultravioleta, lo que la convierte en una herramienta valiosa para la toma de decisiones informadas y el diseño eficiente de sistemas fotovoltaicos.

Palabras Claves: Predicción UV, Machine learning UV,

ABSTRACT

The thesis Predictive Model to Estimate the Ultraviolet Solar Radiation Index in the Lambayeque Region focuses on a quantitative-descriptive research with an applied approach. Its objective is to develop an accurate Machine Learning model to estimate the solar ultraviolet radiation index in Lambayeque. This involves a comprehensive literature review that guides the identification and application of Machine Learning techniques, culminating in a robust model that can capture the complexity of the data and make accurate estimates. The availability of a dataset that includes daily records and previous studies on solar ultraviolet radiation in the region is crucial for training and validating the model, improving its accuracy. The construction and validation of this database are essential steps to ensure optimal performance of the model and its ability to estimate accurately in new situations. This model has applications in health, outdoor activities, sun exposure prevention measures and the sizing of photovoltaic systems. Overall, this tool can generate accurate estimates of the solar ultraviolet radiation index, making it a valuable tool for informed decision making and efficient PV system design.

Keyword: UV Prediction, Machine Learning UV,

INTRODUCCIÓN

La energía solar se ha convertido en una fuente prometedora y sostenible para la generación de electricidad en todo el mundo. En particular, en la región de Lambayeque, Perú, se ha reconocido un alto potencial solar que puede ser aprovechado para impulsar el desarrollo de proyectos de energía fotovoltaica. Sin embargo, para lograr una eficiencia óptima en la generación de energía solar, es esencial comprender y tener en cuenta el índice de radiación solar ultravioleta. Este índice juega un papel clave en el diseño y dimensionamiento de sistemas fotovoltaicos, ya que está directamente relacionado con la producción de energía. A pesar de esto, hasta la fecha no se ha desarrollado un modelo predictivo específico para estimar el índice de radiación solar ultravioleta en la región de Lambayeque.

El presente estudio tiene como objetivo abordar esta brecha de conocimiento y desarrollar un modelo predictivo basado en técnicas de aprendizaje automático (Machine Learning) que permita estimar de manera precisa el índice de radiación solar ultravioleta en la región de Lambayeque. Al utilizar datos históricos y otros factores relevantes, se pretende crear un modelo que pueda predecir con exactitud el índice de radiación solar ultravioleta en diferentes períodos de tiempo. Esto proporcionará una valiosa herramienta para los planificadores y desarrolladores de proyectos de energía solar en la región, permitiéndoles tomar decisiones informadas y optimizar el rendimiento de los sistemas fotovoltaicos.

Además, se espera que este modelo predictivo contribuya al avance de la investigación en energía solar y brinde una base sólida para futuros estudios relacionados con la eficiencia y el potencial de generación de energía fotovoltaica en la región de Lambayeque. Al entender mejor el

comportamiento y la variabilidad del índice de radiación solar ultravioleta, se podrán diseñar y desarrollar proyectos solares más eficientes y rentables, impulsando así el crecimiento sostenible de la región y contribuyendo a la transición hacia fuentes de energía más limpias y renovables.

En resumen, este estudio se enfoca en el desarrollo de un modelo predictivo para estimar el índice de radiación solar ultravioleta en la región de Lambayeque. Los resultados obtenidos a partir de este modelo tendrán un impacto significativo en la planificación y el diseño de proyectos de energía solar, promoviendo el aprovechamiento efectivo de la abundante radiación solar disponible en la región y fomentando la adopción de energías renovables en el contexto local y global.

CAPÍTULO I

1.1 DISEÑO TEÓRICO

1.1.1 ANTECEDENTES

Gentili & Campo (2020), Se analiza la distribución espacial y temporal de la radiación solar y su interacción con los elementos físicos, naturales y humanos del entorno en Bahía Blanca, con el fin de proponer medidas para el desarrollo urbano sostenible. Los rayos ultravioletas (UV) son un componente natural crucial, ya que determinan el ambiente terrestre y ejercen un dominio significativo sobre el medio ambiente. La zona del espectro solar correspondiente a los rayos UV tiene un impacto en el sistema formado por todos los seres vivos de la Tierra, es decir, la biosfera. La radiación solar ultravioleta puede tener efectos positivos en diversos procesos, pero también puede ser perjudicial si se produce una exposición fuera de los rangos recomendados.

Abril et al., (2019), Se llevó a cabo un estudio para obtener y comparar el índice de radiación solar en el barrio San Felipe de la ciudad de Latacunga durante el año 2019. Se desarrolló un equipo especializado capaz de medir el índice de rayos UV-B, conocidos por ser perjudiciales para la piel humana. La medición se realizó mediante un sensor óptico y un filtro de luz ultravioleta. A través de un programa diseñado específicamente, se mostraron los resultados en forma de códigos de colores, los cuales son de fácil comprensión e interpretación y siguen las pautas establecidas por la Organización Mundial de la Salud (OMS). El índice UV solar mundial es una medida de la intensidad de la

radiación UV en la superficie terrestre, donde el tono violeta indica un nivel de peligro más alto, mientras que el verde señala que no hay riesgo.

(Cruz, 2020) La radiación ultravioleta (UV) que alcanza la Tierra abarca un amplio espectro de longitudes de onda, que van desde los rayos gama hasta las ondas de radio de baja frecuencia, también conocidas como rayos infrarrojos. Sin embargo, gran parte de la radiación UV dañina para los seres humanos es absorbida por la capa de ozono. La radiación UV tiene longitudes de onda más cortas que la luz visible, oscilando entre los 100 nm y los 400 nm, lo que la hace invisible para el ojo humano. Sin embargo, esta radiación puede causar daños en los seres humanos.

Yaulilahua et al., (2022), Se demostró que el índice de rayos UV en otoño es similar al índice de radiación solar en verano, mientras que se verificó que el índice de radiación solar en invierno es similar al de primavera. Además, se observó que los índices de radiación en otoño y verano son más bajos que los de invierno y primavera.

(Gastelo et al., 2018), Presenta un estudio que ofrece información diaria sobre el índice de radiación solar, lo cual resulta beneficioso para el desarrollo de sistemas fotovoltaicos tanto en la ciudad de Lambayeque como en todo el territorio peruano de manera rápida y confiable. El estudio se basó en el modelo de Hargreaves - Samani, que utiliza datos de temperaturas máximas y mínimas para estimar la radiación solar. Los resultados revelaron que la ciudad de Lambayeque tiene una irradiación solar global promedio anual de 5.38 kWh/m²/día, lo que se traduce en una energía total anual de 1.96 MWh/m². Estos datos

demuestran que la región cuenta con un potencial solar altamente rentable, de acuerdo con la clasificación de la Organización Latinoamericana de Energía (OLADE)..

1.2 BASES TEÓRICAS

1.2.1 La Radiación Solar:

La radiación solar es una forma de energía electromagnética emitida por el Sol que alcanza la Tierra. Está compuesta por varios componentes, incluyendo la radiación ultravioleta (UV), la radiación visible y la radiación infrarroja (IR) (Kumar et al., 2020). Cada componente tiene diferentes longitudes de onda y propiedades que interactúan con la atmósfera y la superficie terrestre.

La radiación ultravioleta (UV) es una parte importante de la radiación solar y se divide en tres categorías: UV-A, UV-B y UV-C. La radiación UV-A tiene longitudes de onda que van de 315 nm a 400 nm, la radiación UV-B tiene longitudes de onda de 280 nm a 315 nm, y la radiación UV-C tiene longitudes de onda menores a 280 nm (Lohmann et al., 2021). Estos componentes tienen diferentes capacidades de penetración en la atmósfera y efectos en la salud humana y el medio ambiente.

La radiación solar desempeña un papel fundamental en la sostenibilidad de la vida en la Tierra. La radiación ultravioleta (UV) es esencial para la producción de vitamina D en la piel humana, pero una exposición excesiva puede tener efectos perjudiciales en la salud, como quemaduras solares, envejecimiento prematuro de la piel y aumento del riesgo de cáncer de piel (Nasti et al., 2020). La radiación visible es responsable de la iluminación natural y la fotosíntesis de las plantas, mientras que la radiación infrarroja contribuye al calentamiento del planeta y los procesos climáticos (Raschke et al., 2020).

La comprensión de la radiación solar y sus componentes es crucial en diversas disciplinas, como la climatología, la meteorología, la salud y la energía renovable. La monitorización y el análisis de la radiación solar permiten pronosticar el clima, evaluar los riesgos para la salud y optimizar el aprovechamiento de la energía solar (Pandithurai et al., 2020).

1.2.2 Radiación Ultravioleta

La radiación solar ultravioleta (UV) es una parte importante de la radiación solar que llega a la Tierra. Se clasifica en tres categorías principales: UV-A, UV-B y UV-C, según su longitud de onda y su capacidad de penetración en la atmósfera (Fioletov et al., 2020).

La radiación UV-A tiene longitudes de onda que van de 315 nm a 400 nm y representa la mayor parte de la radiación UV que alcanza la superficie terrestre. Tiene la capacidad de penetrar profundamente en la piel y puede causar daño acumulativo, como el envejecimiento prematuro de la piel y el desarrollo de cáncer de piel (Godar et al., 2020).

La radiación UV-B, con longitudes de onda que van de 280 nm a 315 nm, es más energética y tiene efectos más perjudiciales para la salud humana. La sobreexposición a la radiación UV-B puede causar quemaduras solares, daño en el ADN y aumentar el riesgo de cáncer de piel (Lim et al., 2020).

La radiación UV-C, con longitudes de onda menores a 280 nm, es altamente energética y generalmente es absorbida por la capa de ozono y otros componentes atmosféricos, por lo que no llega a la superficie terrestre en grandes cantidades (World Meteorological Organization, 2020).

El monitoreo y la comprensión de la radiación solar ultravioleta son de vital importancia para la salud humana y la protección contra los efectos nocivos de la exposición excesiva.

La Organización Mundial de la Salud (OMS) establece índices de radiación UV y brinda recomendaciones sobre la protección adecuada contra la radiación (World Health Organization, 2020).

En el contexto de la región de Lambayeque, comprender la radiación solar ultravioleta y su variabilidad es esencial para evaluar los riesgos asociados y promover prácticas de protección adecuadas. En esta tesis, se desarrollará un modelo predictivo para estimar el índice de radiación solar ultravioleta en la región, utilizando datos actuales y variables ambientales relevantes. Esto permitirá obtener información precisa y oportuna sobre la radiación UV y contribuirá a la promoción de la salud y la prevención de enfermedades relacionadas con la exposición solar.

1.2.3 Factores que afectan la radiación UV:

Un análisis de los diferentes factores que influyen en la intensidad de la radiación UV, como el ozono atmosférico, la altitud, la latitud, la elevación solar, las condiciones climáticas y otros factores ambientales.

La intensidad de la radiación ultravioleta (UV) está influenciada por una serie de factores que interactúan en la atmósfera y en la superficie terrestre. Uno de los factores clave es el ozono atmosférico, el cual actúa como un filtro que absorbe gran parte de la radiación UV-B y UV-C antes de que alcance la superficie terrestre (Kong et al., 2021). La variabilidad en la concentración de ozono puede resultar en cambios significativos en la intensidad de la radiación UV.

La altitud también desempeña un papel importante en la intensidad de la radiación UV. A medida que aumenta la altitud, la atmósfera se vuelve más delgada, lo que resulta en una

menor absorción de radiación UV y, por lo tanto, en una mayor intensidad en las zonas de mayor altitud (Müller et al., 2020). La latitud también juega un papel, ya que las regiones cercanas al ecuador reciben una mayor intensidad de radiación UV en comparación con las regiones polares.

La elevación solar, que depende de la hora del día y la época del año, también afecta la intensidad de la radiación UV. Durante el mediodía solar, cuando el sol se encuentra en su punto más alto en el cielo, la radiación UV es más intensa debido a un ángulo de incidencia más perpendicular (Siani et al., 2020). Por otro lado, en horas de la mañana y tarde, el ángulo de incidencia es más oblicuo, lo que reduce la intensidad de la radiación UV.

Además, las condiciones climáticas y otros factores ambientales también pueden influir en la intensidad de la radiación UV. La presencia de nubes puede bloquear parte de la radiación UV, mientras que la reflectividad de la superficie terrestre y la cantidad de aerosoles en la atmósfera también pueden afectar la cantidad de radiación UV que alcanza la superficie terrestre (Li et al., 2020).

El análisis de estos factores es fundamental para comprender la variabilidad de la radiación UV y sus impactos en la salud humana y el medio ambiente. Además, permite desarrollar modelos predictivos más precisos para estimar la intensidad de la radiación UV en diferentes ubicaciones y momentos del día, lo que es de gran importancia para la protección de la piel y la toma de decisiones en actividades al aire libre.

1.2.4 Mediciones y estimaciones de radiación UV:

Una revisión de los métodos utilizados para medir y estimar la radiación UV, incluyendo instrumentos y técnicas utilizados en estudios previos.

La medición y estimación de la radiación ultravioleta (UV) es fundamental para comprender sus efectos en la salud humana y el medio ambiente. En la última década, se han desarrollado y utilizado diversos métodos y tecnologías para realizar estas mediciones y estimaciones.

Entre los instrumentos utilizados para medir la radiación UV se encuentran los radiómetros UV, que registran la intensidad de la radiación en diferentes longitudes de onda. Estos instrumentos suelen tener filtros específicos para medir las distintas bandas de radiación UV, como UV-A, UV-B y UV-C (Zhu et al., 2020). Además, se utilizan espectrofotómetros y dosímetros UV, que proporcionan mediciones más precisas y detalladas de la radiación UV (Díaz et al., 2020).

En cuanto a las técnicas de estimación, se han desarrollado modelos matemáticos y algoritmos que utilizan variables como la elevación solar, la latitud, la altitud y la concentración de ozono para estimar la radiación UV (Njoku et al., 2021). Estos modelos se basan en la relación entre estas variables y la radiación UV medida en estaciones de monitoreo.

Además, se han utilizado técnicas de teledetección mediante satélites para estimar la radiación UV a gran escala. Estos satélites recopilan datos de radiación solar y utilizan algoritmos para calcular la radiación UV en diferentes regiones (Fioletov et al., 2020). Esta información satelital es especialmente útil para obtener estimaciones de la radiación UV en áreas donde no hay estaciones de monitoreo terrestres.

Es importante destacar que cada método de medición y estimación tiene sus ventajas y limitaciones, y su elección depende de los objetivos específicos del estudio y de la disponibilidad de recursos. La combinación de diferentes métodos y técnicas puede

proporcionar estimaciones más precisas y completas de la radiación UV en diferentes ubicaciones y condiciones atmosféricas.

1.2.5 Efectos en la Salud Humana

Los estudios sobre mutagénesis adquieren cada día mayor importancia en el ámbito mundial, por el constante deterioro al que está sujeto el hábitat del hombre moderno. Por tal motivo, los seres humanos se encuentran expuestos a la acción de numerosos agentes genotóxicos (agentes capaces de dañar al DNA). (Rodríguez, 2020). Entre ellos se encuentra la radiación UV cada día con mayor incidencia sobre la tierra producto a la reducción de la capa de ozono. El cáncer de piel es uno de los efectos más severos que producen las radiaciones UV. En la actualidad los tumores de piel son el tipo más frecuente de neoplasias humanas. (González et al., 2009)

Las radiaciones ultravioletas constituyen uno de los agentes físicos causantes de mutaciones en los más diversos organismos de nuestro planeta y éstas están indisolublemente ligadas a los procesos de foto carcinogénesis. (Kozmin et al., 2005)

La luz solar supone la principal fuente de exposición a radiación electromagnética. Dentro de este espectro, puede diferenciarse radiación ultravioleta (290-400 nm), luz visible (400-800 nm) y luz infrarroja (800-1700 nm). De todos ellos, la radiación ultravioleta es el principal responsable de los efectos nocivos derivados de la exposición solar, a pesar de suponer únicamente el 5% de la exposición a radiaciones en la superficie terrestre. (Burgos-Blasco et al., 2022)

1.2.6 Efectos cutáneos de la radiación ultravioleta

La radiación ultravioleta se puede categorizar en tres tipos según su longitud de onda: UVC (200-290 nm), UVB (290-320 nm) y UVA (320-400 nm). En la superficie terrestre, nuestra exposición se limita a la radiación UVA y UVB, ya que la mayoría de la radiación UVC es absorbida por la capa de ozono en la estratosfera. (Lyons et al., 2021)

La lesión directa al ADN después de la exposición a la radiación ultravioleta ocurre cuando el ADN absorbe la energía de esta radiación, que alcanza su punto máximo de absorción a una longitud de onda de 260 nm. En proximidad a este pico se encuentra la radiación UVB, que, por lo tanto, tiene un mayor potencial mutagénico, a pesar de su capacidad de penetración moderada y de ser en gran medida filtrada por la atmósfera. Esta capacidad conduce a la formación de enlaces covalentes entre bases de pirimidina, que, si no se reparan, contribuyen al desarrollo de cáncer. (Kullavanijaya & Lim, 2005)

Además, hay una mayor exposición a la radiación UVA, que, aunque tiene menos energía, penetra con mayor profundidad en la piel. Esta radiación es responsable de la pigmentación de la piel y del proceso de envejecimiento. También contribuye directamente a la formación de especies reactivas de oxígeno, lo que puede provocar daño celular, y de manera indirecta al interferir con los mecanismos de reparación celular y reducir la cantidad de células presentadoras de antígenos, lo que aumenta el riesgo de cáncer inducido por la luz solar. (Kutlubay et al., 2014)

Aunque la radiación ultravioleta tiene ciertos efectos beneficiosos, como estimular la síntesis de vitamina D y mejorar algunas afecciones de la piel, como la psoriasis, se cree que los efectos perjudiciales de la exposición a esta radiación superan sus ventajas. (Rigel et al., 2022 & Burgos-Blasco et al., 2022)

1.2.7 Factores que Influyen en la Variabilidad UV

1.2.7.1 Factores Geográficos:

- **Latitud:** Cuanto más cerca de los polos te encuentres, menor será la intensidad de la radiación UV debido al ángulo más oblicuo con el que los rayos del sol inciden en la superficie.
- **Altitud:** A mayores altitudes, la atmósfera es más delgada y, por lo tanto, hay menos filtración de la radiación UV. Esto puede resultar en niveles más altos de radiación UV en zonas de mayor altitud.
- **Cobertura de Nubes:** La presencia de nubes puede bloquear y dispersar parte de la radiación UV, reduciendo su intensidad en la superficie.
- **Superficie Reflectante:** Superficies como la nieve, el agua y la arena pueden reflejar la radiación UV, aumentando la exposición en áreas circundantes.

1.2.7.2 Factores Temporales:

- **Hora del Día:** La intensidad de la radiación UV es mayor al mediodía, cuando el sol está directamente sobre la cabeza y los rayos atraviesan una menor cantidad de atmósfera.
- **Estación del Año:** La inclinación axial de la Tierra causa variaciones en la intensidad de la radiación UV a lo largo del año. En el hemisferio norte, la radiación UV es generalmente más intensa durante el verano.
- **Duración de la Exposición:** Cuanto más tiempo estés expuesto al sol, mayor será la dosis total de radiación UV que recibas.

1.2.7.3 Factores Meteorológicos:

- **Espesor de la Atmósfera:** La radiación UV debe atravesar la atmósfera antes de llegar a la superficie. Un espesor atmosférico mayor resulta en una mayor absorción y dispersión de la radiación UV.
- **Contaminación Atmosférica:** Partículas en suspensión y contaminantes en el aire pueden afectar la cantidad de radiación UV que alcanza la superficie.
- **Índice de Ozono:** El ozono estratosférico absorbe gran parte de la radiación UV-B y UV-C. Los cambios en la capa de ozono pueden tener un impacto significativo en la intensidad de la radiación UV.
- **Humedad:** La humedad atmosférica puede afectar la cantidad de radiación UV que llega a la superficie, aunque en menor medida que otros factores.
- **Altitud de la Nube:** Las nubes altas pueden permitir que más radiación UV pase a través de ellas en comparación con nubes bajas y densas.
- **Ángulo de Incidencia:** El ángulo entre los rayos del sol y la superficie de la Tierra puede afectar la intensidad de la radiación UV. Un ángulo más bajo puede resultar en una mayor dispersión y filtración de la radiación.

1.2.8 Características geográficas y climáticas de la Región Lambayeque que influyen en la radiación UV

La Región Lambayeque, ubicada en el norte de Perú, tiene características geográficas y climáticas que influyen en la radiación ultravioleta (UV). Las cuales pueden afectar la intensidad y la variabilidad de la radiación UV en la región.

- **Latitud y Altitud:**

Lambayeque se encuentra cerca del ecuador terrestre, lo que implica que la región generalmente recibe altos niveles de radiación solar durante todo el año. La cercanía al ecuador contribuye a una exposición más directa al sol y, por lo tanto, a niveles más altos de radiación UV en comparación con regiones más alejadas del ecuador.

- **Clima Desértico Costero:**

La región Lambayeque tiene un clima desértico costero caracterizado por una baja humedad atmosférica y escasas precipitaciones. Este clima favorece la presencia de días soleados y despejados, lo que puede aumentar la intensidad de la radiación UV en la superficie.

- **Índice de Radiación UV Variante:**

La intensidad de la radiación UV puede variar según la época del año. La región experimenta una estación seca que coincide con el invierno del hemisferio sur (de mayo a octubre) y una estación húmeda durante el verano (de noviembre a abril). Durante la estación seca, la disminución de la humedad y la menor cantidad de nubes pueden aumentar la radiación UV.

- **Efectos de la Corriente de Humboldt:**

La Corriente de Humboldt, una corriente marina fría del océano Pacífico, tiene un impacto en el clima de la región. Puede causar nieblas costeras y nubosidad durante ciertas épocas del año, lo que podría reducir temporalmente la intensidad de la radiación UV.

- **Altitud Variable:**

Aunque Lambayeque es principalmente una región costera, también incluye áreas de altitud variable, especialmente en las zonas cercanas a los Andes. La altitud puede tener un impacto en la intensidad de la radiación UV, ya que la radiación tiende a ser más intensa en altitudes más elevadas debido a la menor atmósfera que debe atravesar.

- **Condiciones Geográficas Locales:**

La presencia de cuerpos de agua, vegetación y otros elementos geográficos locales puede influir en la dispersión y absorción de la radiación UV en la región, lo que podría dar lugar a patrones de radiación UV variables en diferentes áreas de Lambayeque.

1.2.9 Modelos Estadísticos

Las técnicas de pronóstico buscan obtener valores futuros bajo incertidumbre utilizando información histórica para identificar patrones de comportamiento. Se basan en los principios del Aprendizaje Automático, que mejora la precisión de las predicciones mediante el uso de datos históricos en el proceso de entrenamiento.

Existen varios modelos estadísticos que se pueden utilizar para predecir, algunos de los modelos más comunes incluyen:

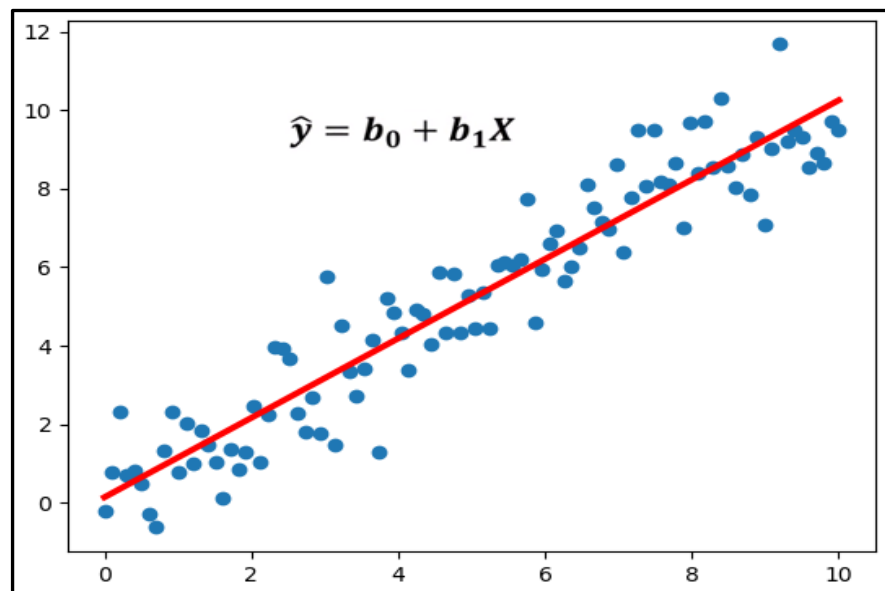
1.2.9.1 Regresión lineal:

La regresión lineal establece una relación lineal entre una variable dependiente y variables independientes, buscando ajustarse a los datos mediante la minimización del error. Utilizando métodos de estimación como mínimos cuadrados ordinarios, se determinan coeficientes que indican la magnitud y dirección de la relación entre

las variables (Fox, 2021). Se aplica en diversas disciplinas para pronósticos, análisis de tendencias y toma de decisiones basadas en datos. Puede ampliarse para incluir términos polinómicos o interacciones, capturando relaciones no lineales o efectos de interacción en el modelo. (Sharma et al., 2021)

Figura 1:

Regresión lineal



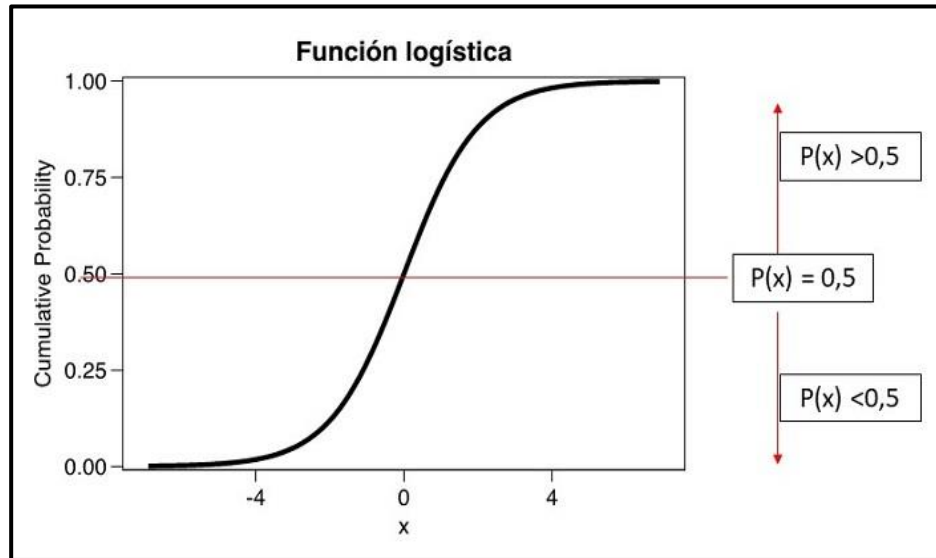
1.2.9.2 Regresión logística:

La regresión logística es un modelo estadístico utilizado para predecir la probabilidad de ocurrencia de un evento binario. Se enfoca en variables categóricas y busca encontrar los coeficientes que mejor separan las dos categorías (Agresti, 2018). Se basa en la función logit y utiliza la máxima verosimilitud para estimar los coeficientes. Las interpretaciones se realizan en términos de odds ratio. Tiene aplicaciones en medicina, epidemiología, psicología y análisis empresarial. Ayuda

en la clasificación de casos y la comprensión de la relación entre variables predictoras y el resultado binario. (Gan et al., 2020)

Figura 2:

Modelo Estadístico Regresión Logísticas

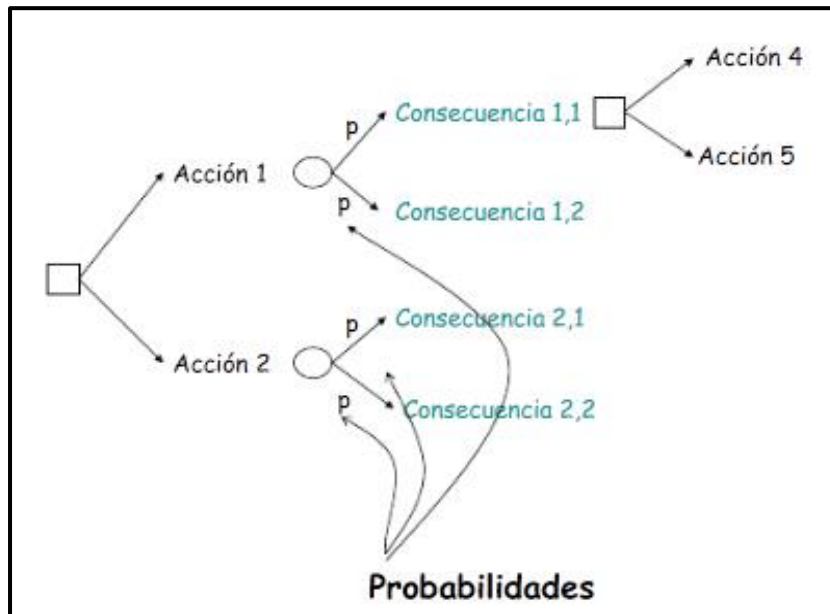


1.2.9.3 Árboles de decisión:

Los árboles de decisión son un modelo de aprendizaje automático que utiliza una estructura jerárquica para tomar decisiones basadas en características importantes. Son fáciles de interpretar y visualizar, utilizados en clasificación y regresión. Pueden sufrir de sobreajuste, pero se pueden mejorar mediante técnicas como la poda y el ensamblaje de árboles en bosques aleatorios. Los árboles de decisión son ampliamente utilizados en diversos campos y permiten generar predicciones confiables basadas en las características más relevantes. (Friedberg et al., 2021)

Figura 3:

Modelo Estadístico de Árboles de decisión

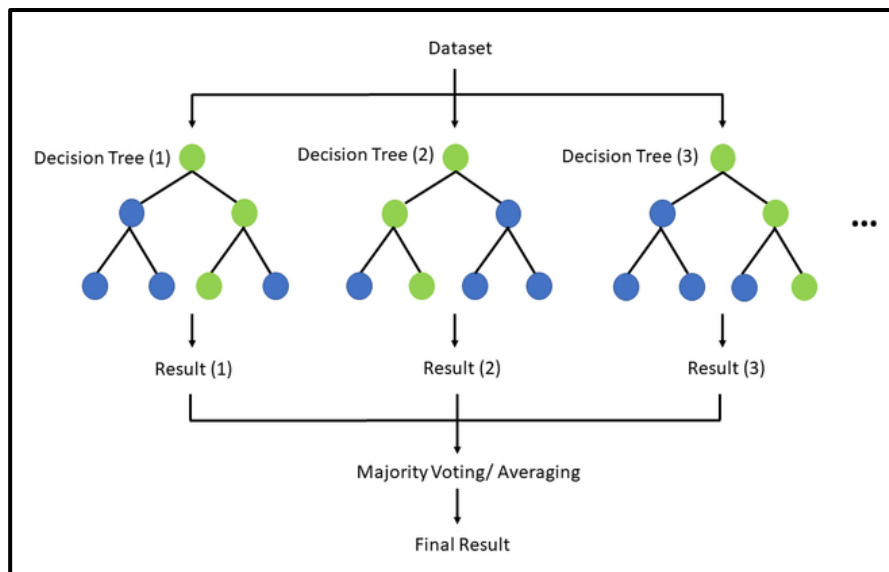


1.2.9.4 Random Forest:

Random Forest es un modelo de aprendizaje automático que se basa en la construcción de múltiples árboles de decisión y combina sus resultados para obtener predicciones más precisas y estables. En este modelo, cada árbol se entrena con una muestra aleatoria de datos y utiliza una selección aleatoria de características. Luego, las predicciones de cada árbol se combinan mediante votación o promedio para producir la predicción final. Random Forest tiene varias ventajas, como la capacidad de manejar grandes conjuntos de datos con características de alta dimensionalidad, la resistencia al sobreajuste y la capacidad de estimar la importancia de las características (Valavi et al., 2021). Además, es adecuado tanto

para problemas de clasificación como de regresión. Random Forest ha demostrado su eficacia en una amplia gama de aplicaciones, como la detección de fraudes, el diagnóstico médico y la predicción del comportamiento del consumidor.(Bénard et al., 2021)

Figura 4:
Modelo Estadístico Random Forest



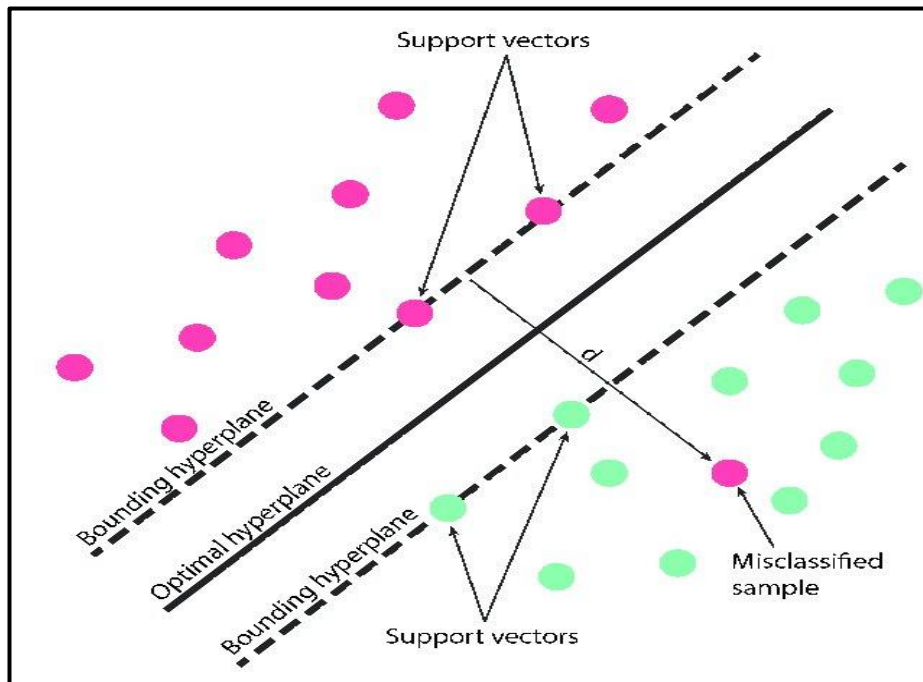
1.2.9.5 Support Vector Machines (SVM):

Es un modelo de aprendizaje automático que se utiliza tanto para problemas de clasificación como de regresión. Su objetivo principal es encontrar un hiperplano en un espacio dimensional superior que pueda separar de manera óptima las clases de datos. SVM busca maximizar la distancia entre el hiperplano y los puntos de datos más cercanos, conocidos como vectores de soporte. Esta distancia se conoce como margen y contribuye a la capacidad de generalización del modelo. Además, SVM tiene la capacidad de utilizar funciones de kernel para transformar los datos

en espacios de características no lineales, permitiendo así resolver problemas no lineales de manera eficiente. SVM ha demostrado ser efectivo en una variedad de aplicaciones, como reconocimiento de imágenes, clasificación de texto y detección de anomalías. (Hao et al., 2022)

Figura 5:

Modelo Estadístico Support Vector Machines (SVM)



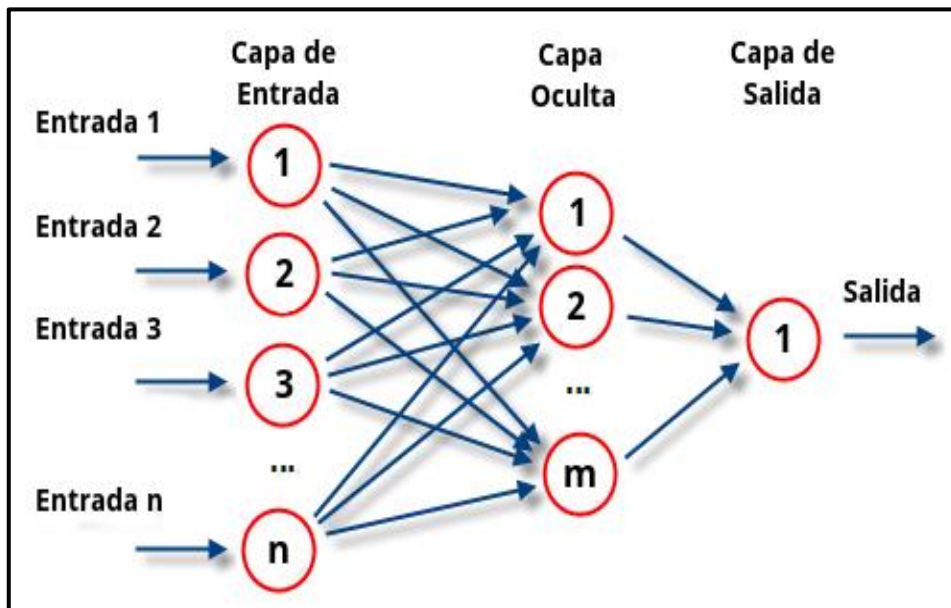
1.2.9.6 Redes neuronales:

Las redes neuronales son un modelo estadístico inspirado en el funcionamiento del cerebro humano. Consisten en una red interconectada de unidades de procesamiento llamadas neuronas, que trabajan en conjunto para realizar tareas de aprendizaje y predicción. Cada neurona realiza cálculos en base a las entradas recibidas y aplica una función de activación para producir una salida. Estas redes son capaces de

aprender patrones complejos a partir de grandes conjuntos de datos, ajustando los pesos de las conexiones entre neuronas a través de algoritmos de optimización. Las redes neuronales se utilizan en una amplia gama de aplicaciones, como reconocimiento de voz, visión por computadora y procesamiento de lenguaje natural, debido a su capacidad para modelar relaciones no lineales y capturar características de alto nivel en los datos. (Goodfellow et al., 2020)

Figura 6:

Modelo Estadístico de Redes Neuronales



1.2.10 Modelos Predictivos Para El Pronóstico De La Radiación UV

1.2.10.1 Modelos de Regresión:

Los modelos de regresión estadística son comunes en el pronóstico de la radiación UV. Se recopilan datos históricos de radiación UV y se relacionan con variables predictoras, como la hora del día, la estación del año, la latitud, la longitud, la altitud y la cobertura de nubes.

Se ajusta una función matemática a estos datos para capturar las relaciones entre las variables predictoras y la radiación UV.

Estos modelos pueden ser lineales o no lineales, y pueden incluir interacciones y términos polinómicos para capturar patrones más complejos.

1.2.10.2 Modelos de Series Temporales:

Los modelos de series temporales se utilizan para identificar patrones y tendencias en los datos históricos de radiación UV a lo largo del tiempo.

Se pueden aplicar métodos como ARIMA (AutoRegressive Integrated Moving Average) y modelos más avanzados como SARIMA (Seasonal ARIMA) para modelar la estacionalidad y las fluctuaciones a corto y largo plazo.

Estos modelos permiten predecir futuros valores de radiación UV en función de los patrones identificados.

1.2.10.3 Modelos de Aprendizaje Automático:

Los algoritmos de aprendizaje automático, como las redes neuronales, los bosques aleatorios y las máquinas de soporte vectorial, pueden utilizarse para pronosticar la radiación UV.

Estos modelos pueden capturar relaciones no lineales y complejas entre las variables predictoras y la radiación UV, lo que puede mejorar la precisión del pronóstico.

Se requiere una gran cantidad de datos de entrenamiento para ajustar estos modelos correctamente.

1.2.10.4 Modelos Físicos y Empíricos:

Algunos enfoques utilizan modelos físicos que consideran la interacción de la radiación solar con la atmósfera y la superficie terrestre. Estos modelos pueden ser más complejos, pero también más precisos.

Los modelos empíricos pueden basarse en relaciones observadas entre variables meteorológicas y radiación UV en un lugar específico.

1.2.10.5 Integración de Datos Meteorológicos:

Los datos meteorológicos, como la humedad, la temperatura, la presión atmosférica y la cobertura de nubes, son factores críticos para el pronóstico de la radiación UV.

La integración de estos datos en los modelos de pronóstico puede mejorar significativamente la precisión de las predicciones.

1.2.10.6 Validación y Ajuste:

Los modelos deben ser validados utilizando datos de monitoreo en tiempo real. Se comparan las predicciones con las mediciones reales para evaluar la exactitud del modelo. Si es necesario, se realizan ajustes en los modelos para mejorar su rendimiento.

1.2.11 Desarrollo del modelo de aprendizaje automático

1.2.11.1 La selección de características relevantes

Es un paso crítico en la aplicación de modelos de aprendizaje automático para pronosticar la radiación ultravioleta (UV). La elección cuidadosa de las variables predictoras que se utilizarán para entrenar el modelo puede tener un impacto significativo en la calidad y precisión de las predicciones.

1.2.11.2 Importancia de la Selección de Características:

- a. Reducción de la Dimensión:** Muchas aplicaciones de pronóstico de radiación UV pueden involucrar múltiples variables potenciales. La selección de características ayuda a reducir la dimensión del conjunto de datos, lo que mejora la eficiencia computacional y puede prevenir el sobreajuste.
- b. Mejora de la Interpretación:** Al seleccionar características relevantes, se puede mejorar la interpretación de los resultados del modelo. Esto ayuda a comprender las relaciones causales entre las variables y la radiación UV.
- c. Prevención de Ruido:** No todas las características tienen igual importancia. Incluir características irrelevantes o ruidosas puede introducir ruido en el modelo y deteriorar la precisión de las predicciones.

1.2.11.3 El Preprocesamiento De Datos

Es una etapa esencial en la aplicación de modelos de aprendizaje automático para pronosticar la radiación ultravioleta (UV). Esta fase implica la preparación y limpieza de los datos brutos antes de introducirlos en el modelo. Un

preprocesamiento adecuado garantiza que los datos sean coherentes, relevantes y adecuados para el análisis y la modelización.

1.2.11.4 Importancia del Preprocesamiento de Datos:

- a. Limpieza de Datos:** Los datos suelen tener ruido, valores atípicos (outliers) o valores faltantes. El preprocesamiento implica identificar y manejar estos problemas para evitar que afecten negativamente los resultados del modelo.
- b. Consistencia:** Los datos pueden estar en diferentes formatos, unidades o escalas. El preprocesamiento asegura que los datos sean coherentes y comparables, lo que es esencial para modelos precisos.
- c. Eficiencia Computacional:** Al eliminar datos innecesarios o redundantes, el preprocesamiento puede mejorar la eficiencia computacional al reducir la cantidad de información que el modelo necesita procesar.
- d. Interpretación:** Preprocesar los datos de manera adecuada puede facilitar la interpretación de los resultados y la identificación de patrones relevantes en el pronóstico de la radiación UV.

1.2.11.5 Pasos Comunes en el Preprocesamiento de Datos:

- a. Limpieza de Valores Atípicos:** Se identifican y gestionan los valores atípicos que pueden distorsionar los resultados. Pueden ser eliminados o tratados mediante técnicas como la imputación.
- b. Gestión de Valores Faltantes:** Los valores faltantes se pueden imputar mediante métodos como la media, la mediana o el uso de modelos predictivos.

- c. **Normalización y Estandarización:** Los datos se escalan para que tengan una media de cero y una desviación estándar de uno (estandarización) o se escalan a un rango específico (normalización). Esto ayuda a evitar que las variables con escalas más grandes dominen el modelo.
- d. **Codificación de Variables Categóricas:** Las variables categóricas se convierten en una forma numérica para que puedan ser procesadas por los algoritmos de aprendizaje automático.
- e. **Eliminación de Características Irrelevantes:** Se pueden eliminar características que no aporten información útil al modelo o que estén altamente correlacionadas con otras.
- f. **Reducción de Dimensionalidad:** En casos de alta dimensionalidad, técnicas como el Análisis de Componentes Principales (PCA) pueden ser utilizadas para reducir el número de características sin perder demasiada información.
- g. **Detección de Datos Duplicados:** Se identifican y eliminan datos duplicados que pueden distorsionar los resultados.
- h. **Tratamiento de Datos Temporales:** Si los datos tienen una dimensión temporal, es importante asegurarse de que estén ordenados adecuadamente y que no haya saltos en el tiempo.
- i. **Partición de Datos:** Los datos se dividen en conjuntos de entrenamiento, validación y prueba para entrenar, ajustar y evaluar el modelo, respectivamente.

1.2.11.6 La Elección Del Modelo

Es un paso clave en la implementación exitosa de pronósticos de radiación ultravioleta (UV) mediante el uso de aprendizaje automático. La selección del modelo adecuado depende de diversos factores y consideraciones, y puede influir significativamente en la precisión y eficacia de las predicciones.

La elección del modelo debe ser un proceso informado y basado en el conocimiento del problema y los datos disponibles. Es importante probar varios modelos y evaluar su rendimiento antes de seleccionar el modelo final para el pronóstico de radiación UV.

1.2.11.7 Importancia de la Elección del Modelo:

- a. Adecuación al Problema: El modelo debe ser apropiado para el problema específico de pronóstico de radiación UV. Diferentes modelos pueden ser más adecuados para diferentes características de datos y relaciones entre variables.
- b. Capacidad de Generalización: Un buen modelo debe ser capaz de generalizar patrones aprendidos de datos de entrenamiento a datos no vistos. La elección del modelo influye en la capacidad de generalización y, por lo tanto, en la calidad de las predicciones.
- c. Complejidad: La complejidad del modelo debe ser adecuada para la cantidad de datos disponibles. Un modelo demasiado complejo puede sobreajustar los datos de entrenamiento y tener un rendimiento deficiente en datos nuevos.

- d. Interpretación: Algunos modelos son más interpretables que otros. La elección del modelo puede influir en la comprensión de cómo las variables predictoras afectan las predicciones.
- e. Eficiencia Computacional: Algunos modelos son más eficientes computacionalmente que otros. La elección del modelo también debe considerar los recursos disponibles.

1.2.11.8 Enfoques Comunes para la Elección del Modelo:

- a. Modelos Lineales: Son simples y fáciles de interpretar. Pueden ser útiles cuando se busca identificar relaciones lineales entre variables predictoras y radiación UV.
- b. Árboles de Decisión: Son eficaces para capturar relaciones no lineales y pueden manejar características categóricas. Pueden ser combinados en bosques aleatorios para mejorar la precisión.
- c. Regresión Polinómica: Puede capturar relaciones no lineales mediante la introducción de términos polinómicos. Puede ser útil cuando se sospecha que las relaciones son curvilíneas.
- d. Máquinas de Soporte Vectorial (SVM): Son efectivas para separar datos en múltiples clases. Pueden manejar características no lineales mediante el uso de funciones de kernel.
- e. Redes Neuronales: Son modelos flexibles que pueden aprender relaciones complejas. Son efectivos para capturar patrones en datos de alta dimensionalidad.

- f. Métodos de Ensamblados: Los ensambles, como los bosques aleatorios y los gradient boosting, combinan múltiples modelos para mejorar la precisión y reducir el sobreajuste.
- g. Modelos de Series Temporales: Si los datos tienen una dimensión temporal, los modelos de series temporales como ARIMA o LSTM pueden ser efectivos para capturar patrones a lo largo del tiempo.
- h. Validación Cruzada: La validación cruzada se puede utilizar para comparar el rendimiento de diferentes modelos en conjuntos de datos de prueba.
- i. Evaluación de Métricas: Se pueden comparar métricas de rendimiento como el error medio absoluto (MAE), el error cuadrático medio (MSE) o el coeficiente de determinación (R^2) para seleccionar el modelo óptimo.

1.2.11.9 El Entrenamiento Del Modelo

Es una etapa fundamental en la aplicación de modelos de aprendizaje automático para pronosticar la radiación ultravioleta (UV). Esta fase implica enseñar al modelo a reconocer patrones en los datos históricos para que pueda realizar predicciones precisas en datos nuevos y no vistos. El entrenamiento del modelo es un proceso iterativo y a menudo requiere ajustes y experimentación para lograr un rendimiento óptimo. Una vez que el modelo está entrenado y evaluado adecuadamente, está listo para realizar pronósticos de radiación UV en nuevos datos.

1.2.11.10 Importancia del Entrenamiento del Modelo:

- a. Captura de Patrones:** Durante el entrenamiento, el modelo busca patrones y relaciones entre las características de los datos de entrenamiento y la radiación UV. Estos patrones permiten al modelo hacer generalizaciones y realizar predicciones en nuevos datos.
- b. Ajuste de Parámetros:** El entrenamiento también implica ajustar los parámetros internos del modelo para minimizar el error en las predicciones. Esto se hace iterativamente para mejorar el rendimiento.
- c. Generalización:** El objetivo final del entrenamiento es lograr que el modelo generalice lo que ha aprendido en datos de entrenamiento a situaciones nuevas y no observadas.

1.2.11.11 Pasos en el Entrenamiento del Modelo:

- a. División de Datos:** El conjunto de datos se divide en datos de entrenamiento y datos de prueba. Los datos de entrenamiento se utilizan para enseñar al modelo, mientras que los datos de prueba se utilizan para evaluar su rendimiento.
- b. Inicialización de Parámetros:** Se inicializan los parámetros internos del modelo con valores iniciales.
- c. Algoritmo de Aprendizaje:** Se utiliza un algoritmo de aprendizaje específico para ajustar los parámetros del modelo en función de los datos de entrenamiento. Esto implica minimizar una función de pérdida que mide el error entre las predicciones del modelo y los valores reales.

- d. Iteraciones:** El proceso de ajuste se realiza en múltiples iteraciones. En cada iteración, el modelo actualiza sus parámetros para reducir el error.
- e. Validación Cruzada:** En algunos casos, se utiliza la validación cruzada para dividir los datos de entrenamiento en subconjuntos de entrenamiento y validación. Esto ayuda a ajustar los hiperparámetros del modelo y prevenir el sobreajuste.
- f. Evaluación del Rendimiento:** Después del entrenamiento, el modelo se evalúa en los datos de prueba para medir su rendimiento en un entorno no visto.
- g. Ajuste y Optimización:** Si el rendimiento no es satisfactorio, los hiperparámetros del modelo pueden ser ajustados y el proceso de entrenamiento se repite.

1.2.11.12 Consideraciones en el Entrenamiento del Modelo:

- a. Sobreajuste y Subajuste:** El sobreajuste ocurre cuando el modelo se adapta demasiado a los datos de entrenamiento y no generaliza bien a nuevos datos. El subajuste ocurre cuando el modelo es demasiado simple para capturar los patrones en los datos. En ambos casos, el rendimiento del modelo se ve comprometido.
- b. Regularización:** Técnicas de regularización, como L1 (Lasso) y L2 (Ridge), se pueden aplicar para evitar el sobreajuste controlando la complejidad del modelo.

- c. **Convergencia:** Es importante asegurarse de que el proceso de entrenamiento converja a una solución óptima. Si el modelo no converge, los resultados pueden ser incoherentes.
- d. **Tiempo y Recursos:** Algunos modelos pueden requerir más tiempo y recursos computacionales para entrenarse. Esto debe considerarse en función de los recursos disponibles.

1.2.11.13 La Validación Cruzada

Es una técnica esencial en la evaluación y ajuste de modelos de pronóstico de radiación ultravioleta (UV) basados en aprendizaje automático. Esta técnica ayuda a estimar la capacidad de generalización del modelo en datos no vistos y a identificar problemas como el sobreajuste.

1.2.11.14 ¿Qué es la Validación Cruzada?

La validación cruzada es un método estadístico que divide el conjunto de datos en subconjuntos de entrenamiento y validación para evaluar el rendimiento del modelo. El objetivo es obtener una estimación realista de cómo el modelo se comportará en datos que no ha visto previamente. Hay varios tipos de validación cruzada, y uno de los más utilizados es la validación cruzada k-fold:

1.2.11.15 Validación Cruzada k-fold

- a. **División de Datos:** El conjunto de datos se divide en k subconjuntos (pliegues) del mismo tamaño aproximado. Uno de los pliegues se retiene como conjunto de prueba y los $k-1$ pliegues restantes se utilizan para entrenar el modelo.
- b. **Entrenamiento y Evaluación:** El modelo se entrena k veces, cada vez utilizando un conjunto de prueba diferente y los pliegues restantes para entrenar. En cada iteración, se evalúa el rendimiento del modelo en el conjunto de prueba.
- c. **Promedio de Resultados:** Al final de las k iteraciones, se promedian los resultados de evaluación para obtener una medida más estable del rendimiento del modelo en datos no vistos.

1.2.11.16 Aplicación en Pronóstico de Radiación UV

- a. **Prevención de Sobreajuste:** La validación cruzada ayuda a identificar si el modelo está sobreajustando los datos de entrenamiento. Si el rendimiento en los datos de validación es significativamente peor que en los de entrenamiento, puede ser un indicio de sobreajuste.
- b. **Ajuste de Hiperparámetros:** La validación cruzada se puede utilizar para ajustar los hiperparámetros del modelo. Se prueban diferentes configuraciones en cada pliegue y se seleccionan aquellas que produzcan el mejor rendimiento promedio.

- c. **Estimación del Rendimiento:** La métrica de evaluación, como el error medio absoluto (MAE) o el error cuadrático medio (MSE), calculada en la validación cruzada proporciona una estimación realista del rendimiento del modelo en situaciones del mundo real.
- d. **Generalización:** La validación cruzada ayuda a medir la capacidad de generalización del modelo, es decir, cómo se comportará en datos futuros no observados.
- e. **Variabilidad en el Rendimiento:** La validación cruzada también proporciona una idea de la variabilidad en el rendimiento del modelo en diferentes conjuntos de prueba, lo que es útil para entender la estabilidad del modelo.

1.2.11.17 El Ajuste De Hiperparámetros

Es un paso esencial en la optimización y mejora del rendimiento de los modelos de pronóstico de radiación ultravioleta (UV) basados en aprendizaje automático. Los hiperparámetros son valores configurables que no se aprenden durante el entrenamiento del modelo y afectan su comportamiento y capacidad de generalización. El ajuste adecuado de hiperparámetros puede marcar la diferencia en la precisión y eficacia del pronóstico.

1.2.11.18 Importancia del Ajuste de Hiperparámetros

- a. **Optimización del Rendimiento:** Los hiperparámetros controlan aspectos críticos del modelo, como la complejidad, la regularización y la tolerancia al ruido. Un ajuste óptimo de estos hiperparámetros puede mejorar significativamente el rendimiento del modelo en datos no vistos.
- b. **Prevención de Sobreajuste:** Ajustar adecuadamente los hiperparámetros puede ayudar a prevenir el sobreajuste, que ocurre cuando el modelo se ajusta demasiado a los datos de entrenamiento y no generaliza bien a datos nuevos.
- c. **Generalización:** El ajuste de hiperparámetros contribuye a lograr un equilibrio entre la capacidad del modelo para capturar patrones y su capacidad para generalizar esos patrones a nuevos datos.

1.2.11.19 Técnicas de Ajuste de Hiperparámetros

- a. **Búsqueda Grid:** Se selecciona un conjunto de valores posibles para cada hiperparámetro y se prueban todas las combinaciones posibles (grid search). Se evalúa el rendimiento del modelo para cada combinación y se selecciona la que tenga el mejor rendimiento.
- b. **Búsqueda Aleatoria:** En lugar de explorar todas las combinaciones, se seleccionan valores de hiperparámetros de manera aleatoria y se evalúa el rendimiento. Esta técnica puede ser más eficiente y efectiva en la búsqueda de soluciones óptimas.

- c. **Optimización Bayesiana:** Utiliza métodos basados en probabilidades para encontrar la combinación óptima de hiperparámetros de manera más eficiente que una búsqueda exhaustiva.
- d. **Ajuste Incremental:** Se ajustan los hiperparámetros uno por uno mientras se mantienen las demás constantes. Esto ayuda a comprender cómo cada hiperparámetro afecta el rendimiento.
- e. **Cross-Validation:** La validación cruzada se combina con la búsqueda de hiperparámetros para evaluar el rendimiento en diferentes conjuntos de prueba. Esto evita el sobreajuste en la selección de hiperparámetros.

1.2.11.20 Consideraciones en el Ajuste de Hiperparámetros

- a. **Exploración Exhaustiva:** La búsqueda grid puede ser costosa computacionalmente, especialmente con múltiples hiperparámetros. La búsqueda aleatoria o la optimización bayesiana pueden ser más eficientes.
- b. **Tamaño del Conjunto de Datos:** El tamaño del conjunto de datos afecta la elección de hiperparámetros. Un conjunto de datos más grande puede requerir una regulación más fuerte.
- c. **Interacción entre Hiperparámetros:** Algunos hiperparámetros pueden interactuar entre sí. Es importante considerar estas interacciones durante el ajuste.

- d. Evaluación del Rendimiento:** La elección de la métrica de evaluación (MAE, MSE, etc.) es fundamental para evaluar cómo los hiperparámetros afectan el rendimiento del modelo.
- e. Validación en Múltiples Conjuntos de Prueba:** Puede ser útil dividir los datos en varios conjuntos de prueba y evaluar el rendimiento del modelo ajustado en todos ellos para obtener una estimación más robusta del rendimiento.

1.2.11.21 La Evaluación Del Modelo

Es una etapa crítica en el proceso de pronóstico de radiación ultravioleta (UV) utilizando modelos de aprendizaje automático. Esta fase implica medir y analizar el rendimiento del modelo en datos no vistos para determinar su precisión y su capacidad para generalizar a situaciones reales.

1.2.11.22 Importancia de la Evaluación del Modelo

- a. Medición del Rendimiento:** La evaluación del modelo proporciona una medida objetiva de qué tan bien el modelo está haciendo predicciones en comparación con los valores reales de radiación UV.
- b. Validación de la Precisión:** Permite validar si las predicciones del modelo son precisas y confiables, lo que es fundamental para tomar decisiones basadas en los pronósticos.

- c. **Identificación de Mejoras:** La evaluación del modelo revela posibles áreas de mejora y ajuste que pueden aumentar la precisión de las predicciones.

1.2.11.23 Métricas Comunes de Evaluación

- a. **Error Medio Absoluto (MAE):** Calcula la diferencia promedio entre las predicciones del modelo y los valores reales. Cuanto menor sea el MAE, mejor será la precisión del modelo.
- b. **Error Cuadrático Medio (MSE):** Calcula el promedio de los cuadrados de las diferencias entre las predicciones y los valores reales. El MSE penaliza más los errores grandes.
- c. **Raíz del Error Cuadrático Medio (RMSE):** Es la raíz cuadrada del MSE y se interpreta en las mismas unidades que la variable objetivo. Proporciona una medida de la dispersión de los errores.
- d. **Coefficiente de Determinación (R^2):** Mide la proporción de la varianza total en la variable objetivo que es explicada por el modelo. Un valor más cercano a 1 indica un buen ajuste.
- e. **Error Porcentual Absoluto Medio (MAPE):** Calcula el promedio de los errores porcentuales entre las predicciones y los valores reales. Es útil para evaluar la precisión relativa del modelo.
- f. **Error Medio Relativo (MRE):** Es similar al MAPE pero expresa el error como un decimal en lugar de un porcentaje.

1.2.11.24 Enfoques de Evaluación

- a. **División en Conjuntos de Entrenamiento y Prueba:** Los datos se dividen en dos conjuntos: uno para entrenar el modelo y otro para evaluarlo. Esto puede llevar a una evaluación sesgada si los datos de prueba son limitados.
- b. **Validación Cruzada:** Se divide el conjunto de datos en pliegues para entrenar y evaluar el modelo múltiples veces. Esto proporciona una evaluación más robusta y ayuda a evitar el sobreajuste en la evaluación.
- c. **Validación Temporal:** Si los datos tienen una dimensión temporal, se puede usar la validación temporal, donde se entrena con datos anteriores y se evalúa con datos más recientes.
- d. **Comparación con Modelos Baseline:** Se compara el rendimiento del modelo con un modelo baseline, como la predicción constante o la media histórica.

1.2.11.25 Interpretación de los Resultados:

- a. **Errores Pequeños:** Si las métricas de evaluación indican errores pequeños y consistentes, el modelo puede ser considerado confiable y adecuado para el pronóstico de radiación UV.
- b. **Errores Grandes o Inconsistentes:** Si los errores son grandes o inconsistentes, es necesario revisar el modelo, ajustar hiperparámetros y considerar otras técnicas de modelado.

- c. **Comparación con Baselines:** La comparación con modelos baseline ayuda a comprender si el modelo está agregando valor en comparación con enfoques más simples.

1.2.11.26 La Predicción Futura

Es el objetivo final en la aplicación de modelos de pronóstico de radiación ultravioleta (UV) basados en aprendizaje automático. Implica utilizar el modelo entrenado para realizar estimaciones de los niveles de radiación UV en momentos o fechas futuras.

1.2.11.27 Proceso de Predicción Futura

- a. **Preparación de Datos:** Los datos de entrada para la predicción deben ser preparados y preprocesados de la misma manera que durante el entrenamiento del modelo. Esto asegura que las características tengan la misma escala y formato.
- b. **Alimentación del Modelo:** Se utilizan las características relevantes y preprocesadas como entrada para el modelo entrenado. El modelo procesa las características y genera una estimación de los niveles de radiación UV en el futuro.
- c. **Consideraciones Temporales:** Si los datos tienen una dimensión temporal, la predicción futura implica extender la secuencia temporal con nuevos datos para los momentos futuros.

- d. Visualización y Presentación:** Las predicciones futuras se pueden visualizar en forma de gráficos, series de tiempo o mapas, lo que facilita la interpretación y la toma de decisiones.

1.2.11.28 Aspectos Importantes en la Predicción Futura

- a. Errores de Predicción:** Siempre existe un grado de incertidumbre en las predicciones futuras debido a la variabilidad natural en los datos y a las limitaciones del modelo. Es importante comunicar la incertidumbre junto con las predicciones.
- b. Actualización de Datos:** A medida que se disponga de nuevos datos, es importante actualizar el modelo y reentrenarlo para que pueda capturar patrones más recientes y mejorar las predicciones futuras.
- c. Calibración:** Las predicciones pueden requerir calibración para ajustar cualquier sesgo sistemático o desviación en las estimaciones del modelo.
- d. Evaluación Continua:** Las predicciones futuras deben evaluarse continuamente en comparación con los datos reales para verificar la precisión y la calidad del modelo.
- e. Escenarios Diferentes:** Es útil explorar diferentes escenarios futuros, como cambios en las condiciones climáticas o la incorporación de datos nuevos, para comprender mejor la variabilidad en las predicciones.
- f. Uso en la Toma de Decisiones:** Las predicciones futuras pueden ser herramientas valiosas para la planificación y la toma de decisiones,

como la implementación de medidas de protección solar en áreas con niveles altos de radiación UV.

- g. Comunicación Clara:** La comunicación de las predicciones futuras debe ser clara y comprensible para el público en general y para aquellos que toman decisiones basadas en las predicciones.

1.2.11.29 El Monitoreo y La Actualización

Son aspectos fundamentales en la implementación exitosa y continua de modelos de pronóstico de radiación ultravioleta (uv) basados en aprendizaje automático. Estas etapas aseguran que el modelo siga siendo preciso y relevante a medida que cambian las condiciones y se obtienen nuevos datos.

1.2.11.30 Monitoreo del Modelo

- a. Seguimiento Continuo:** Una vez implementado, es crucial realizar un seguimiento continuo del rendimiento del modelo en comparación con las observaciones reales de radiación UV. Esto permite identificar cualquier deterioro en la precisión del modelo.
- b. Comparación con Datos Observados:** Los pronósticos del modelo deben compararse regularmente con las mediciones reales de radiación UV. Si hay discrepancias significativas, es necesario investigar y corregir posibles problemas.
- c. Identificación de Cambios:** El monitoreo debe detectar cambios en las condiciones o comportamientos que puedan afectar la precisión del

modelo, como cambios estacionales, cambios en la geografía o eventos climáticos extremos.

- d. Evaluación de Incertidumbre:** Junto con el monitoreo del rendimiento, es importante evaluar y comunicar la incertidumbre asociada con las predicciones del modelo.

1.2.11.31 Actualización del Modelo

- a. Reentrenamiento Regular:** A medida que se acumulan nuevos datos, el modelo debe reentrenarse regularmente para incorporar esta información y mejorar su capacidad de generalización.
- b. Actualización de Hiperparámetros:** Los hiperparámetros del modelo también pueden necesitar ajustes a medida que cambian los datos o se obtiene más información sobre su comportamiento.
- c. Incorporación de Nuevas Características:** Si se identifican nuevas características o variables relevantes para el pronóstico de radiación UV, el modelo debe actualizarse para incorporarlas.
- d. Mantenimiento de la Infraestructura:** Además de actualizar el modelo, también es importante mantener la infraestructura tecnológica que lo respalda, como servidores, bases de datos y sistemas de procesamiento.

1.2.11.32 Consideraciones Adicionales

- a.** Período de Evaluación: Definir un período de tiempo regular para evaluar y actualizar el modelo, como cada mes o cada estación, para garantizar que esté actualizado y preciso.
- b.** Versionamiento del Modelo: Mantener un sistema de versionamiento para el modelo y sus componentes, lo que facilita el seguimiento de las actualizaciones y cambios realizados.
- c.** Comunicación y Colaboración: Involucrar a expertos en el campo de la radiación UV, meteorólogos y otros profesionales relacionados para garantizar que las actualizaciones del modelo sean informadas y relevantes.
- d.** Pruebas Rigurosas: Antes de implementar actualizaciones en un entorno de producción, es fundamental realizar pruebas rigurosas para verificar que no haya efectos negativos en el rendimiento del modelo.

1.2.12 Puesta en funcionamiento de Calculadora de UV (Pronostico - UV)

El desarrollo del software se empleó en Python, con herramientas como Numpy, pandas, Matplotlib, y más que sirven para poder determinar la visualización del dato calculado, para poder calcular, se hizo una análisis que comprende la humedad del aire, temperatura del aire, vapor de agua, estos datos nos sirven para poder predecir que si el día tiene una humedad alta y una temperatura alta la radiación se incrementa, para que el usuario final pueda tener la facilidad de la manipulación del sistema se empleó el transformar un archivo

que para apertura pide tener instalado Python a ser un archivo ejecutable, libre de cualquier software complementario.

1.2.12.1 Interfaz grafica

La interfaz gráfica consta de 3 entradas día, mes y año estos datos numéricos sirven para que nuestro sistema determine primero si la fecha ingresa es válido o no, determinar si el año es bisiesto o no, estos datos sirven para el análisis de la predicción, una vez se establezca los resultados, se emplea a ingresar la ecuación de 2do grado que permite proyectar el dato que requerimos.

CAPITULO II

2.1 Métodos y Materiales

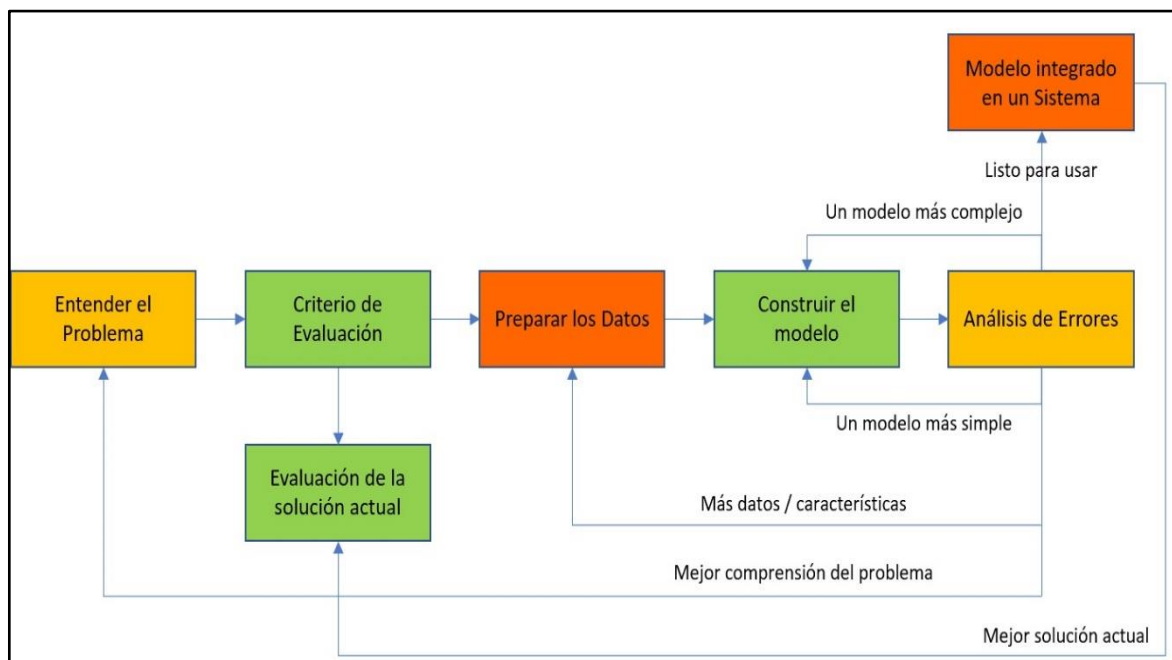
2.1.1 Diseño de Contrastación de Hipótesis

La presente investigación, es del tipo aplicada con un enfoque cuantitativo –descriptivo.

El diseño se muestra en.

Figura 7:

Diseño de Contrastación de Hipótesis



2.2 Población, Muestra

2.2.1 Población

Datasets de Registros diarios y estudios desarrollados.

2.2.2 *Muestra por conveniencia*

Datasets de Registros diarios y estudios desarrollados.

2.3 Técnicas, Instrumentos, Equipos Y Materiales

Usaremos sustento teórico en el diseño y programación del sistema, por lo cual haremos uso de síntesis bibliográfica respaldada por libros. Se usará el lenguaje de programación Python que permita generar un entorno en el cual pueda desarrollarse los resultados y por ende el sistema responsable de realizar el modelo predictivo para estimar el índice de radiación solar ultravioleta en región Lambayeque.

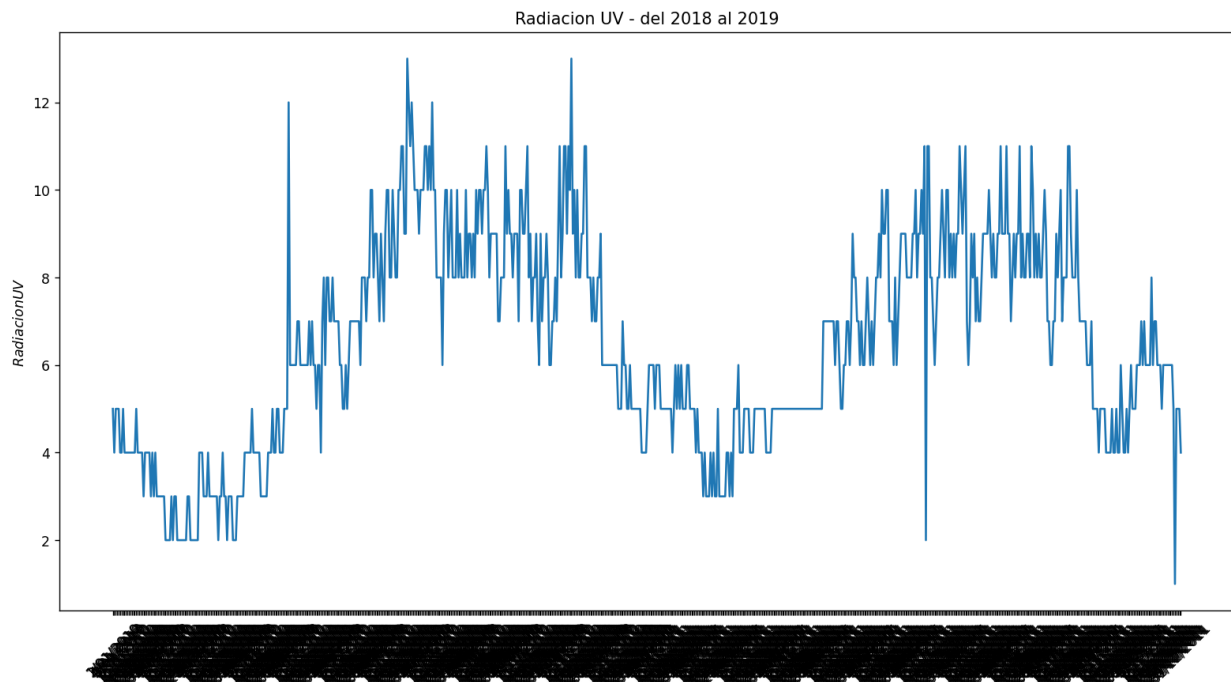
CAPÍTULO III

3.1 RESULTADOS Y DISCUSIÓN

Para este proyecto hemos empleado un sistema de predicción, con ecuaciones que permitan determinar el valor en el día de la radiación UV, este dato lo podemos usar para poder determinar que en un tiempo cercano podamos saber a cuánto asciende la radiación y poder determinar para una obtención positiva como es la energía renovable (paneles solare), y también el prevenir salir si el índice es mayor.

Figura 8:

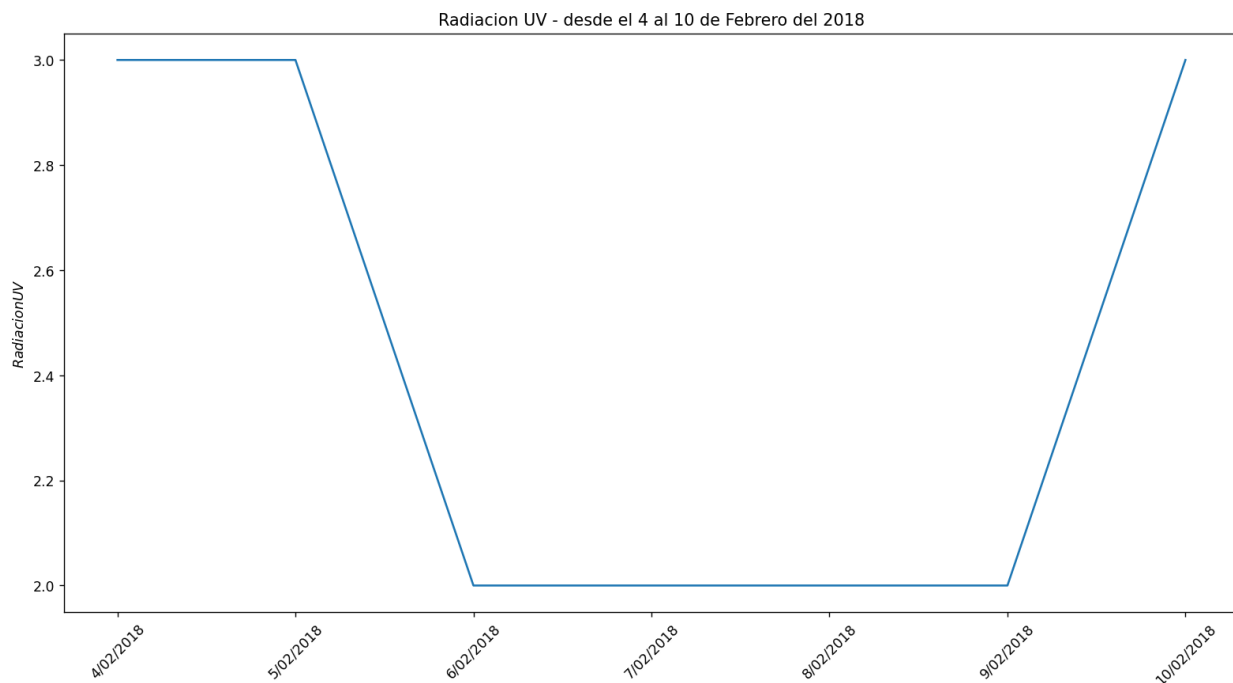
Grafica de la tendencia de la radiación entre los años 2018-2019



En esta grafica se determina la intensidad máxima de la radiación UV en el día, esto comprende desde el 1/1/2018 hasta el 31/1/2019, esto sirve para poder determinar la ecuación que nos podrá determinar el indice UV del sistema.

Figura 9:

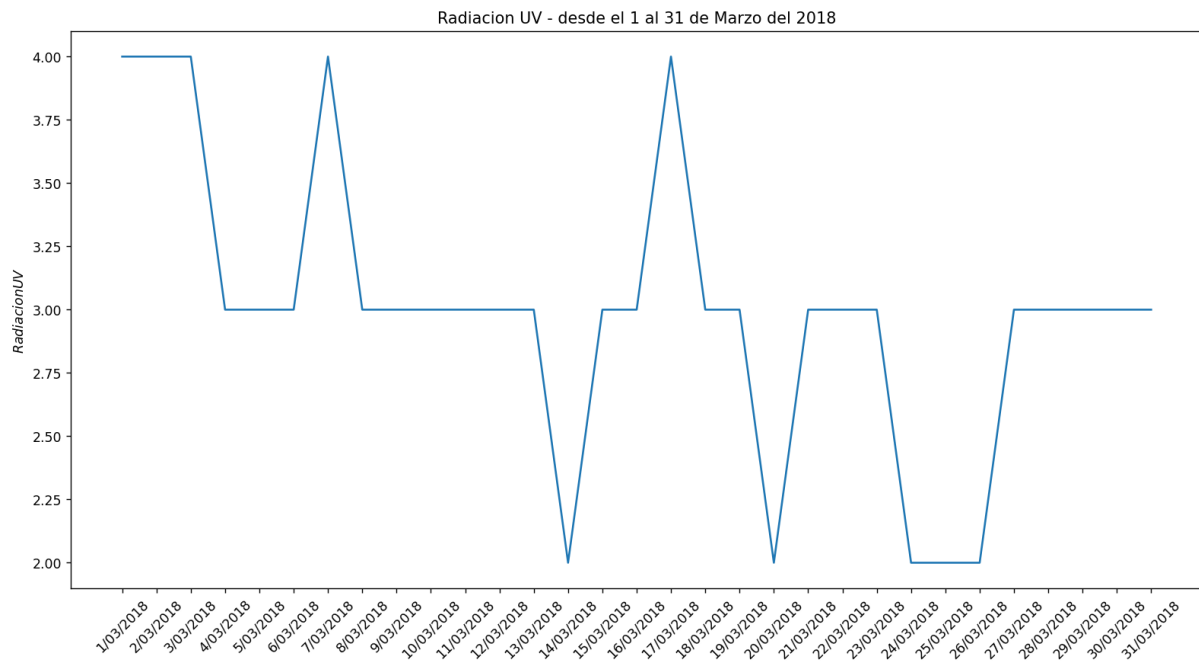
Radiación UV 4-10 de Febrero 2018



Nuestro sistema de ecuación tiene relación entre los datos establecidos y el dato a predecir, es para el cual se determina el valor que se necesita para nuestro sistema. Estas graficas nos sirven para entender en cómo va la variación entre días, semanas, meses y años, esto para ver si el valor del índice de UV aumenta o disminuye, esto para poder determinar que el valor con el menor porcentaje de variación, esto determina que el valor calculado es el más adecuado para el nuestro software.

Figura 10:

Radiación del 1 - 31 de Marzo del 2018



Para esto la variación entre meses que se encuentran podemos determinar los valores para poder calcular el índice de radiación UV.

El porcentaje de variación entre el valor real y el valor calculado es menor a un 10%, esto nos garantiza que nuestro dato calculado es el más optimo.

3.1.1 Procesos Para Pronosticar La Radiación Ultravioleta (UV)

El pronóstico de la radiación UV implica el uso de técnicas estadísticas y modelos matemáticos avanzados para predecir los niveles futuros de radiación ultravioleta en función de datos históricos y variables predictoras.

El proceso para pronosticar la radiación ultravioleta (UV) en la región Lambayeque que utilizaremos será el Modelos de Aprendizaje Automático, el cual se caracteriza en el uso de la inteligencia artificial mediante redes neuronales.

Figura 11:
Aprendizaje Automático

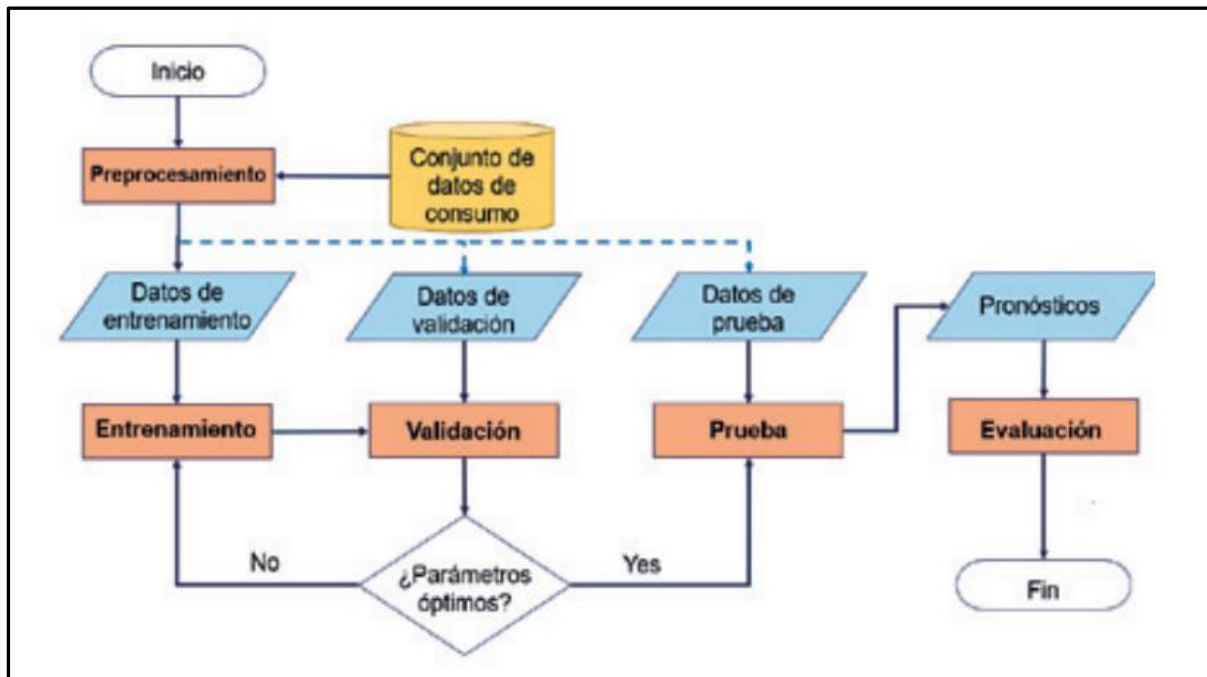


3.1.2 Modelos de Aprendizaje Automático en el Pronóstico de Radiación UV

Los modelos de aprendizaje automático (AA) se han convertido en herramientas poderosas en una variedad de campos, incluido el pronóstico de la radiación UV. Estos modelos pueden capturar relaciones complejas y no lineales entre las variables predictoras y la radiación UV, lo que puede resultar en pronósticos más precisos y detallados.

Figura 14:

Modelos de Aprendizaje Automático en el Pronóstico de Radiación UV



3.1.3 *Desarrollo del modelo de aprendizaje automático*

- 3.1.3.1 Para utilizar el software, es necesario contar con las siguientes bibliotecas: Tkinter, NumPy y Pandas. Este último se utiliza para indexar datos desde un archivo .csv, que posteriormente serán procesados. Dado que los datos que vamos a predecir son variables independientes, utilizamos el análisis predictivo basado en una ecuación polinómica. Esto nos permite analizar los posibles resultados, incluyendo la predicción de los valores de la radiación ultravioleta (UV).
- 3.1.3.2 En relación a las variables de día, mes y año, es importante destacar que estos datos están sujetos a limitaciones. Para garantizar un control adecuado, es necesario realizar comparaciones, verificando tanto la cantidad de días en un mes como si el día está dentro del rango establecido. Además, es crucial considerar si el año es bisiesto, ya que esto determinará la existencia del 29 de febrero y la necesidad de contar con datos correspondientes para ese día.
- 3.1.3.3 Como resultado, contamos con un limitador de rango que abarca desde el día 1 hasta el día 28, 29, 30 o 31, dependiendo del mes correspondiente y del año. Para abordar esta cuestión, se ha evaluado la viabilidad de crear una función que determine automáticamente si el año ingresado es bisiesto o no. En caso de ser automático, se considerará el día 29 como un día válido para la predicción. Esto se realiza con el propósito de garantizar que solo se trabaje con fechas reales y coherentes en el análisis de datos.

3.1.3.4 Cuando el año ingresado no es bisiesto, se tienen automáticamente 365 datos que pueden ser objeto de predicción. Estos se distribuyen en función del mes y el día. A partir de estos datos, realizamos las predicciones necesarias. Para lograrlo, se utiliza la diferencia entre el año ingresado y "2018", que representa el inicio de la base de datos. Esta diferencia se incorpora a la ecuación. Una vez que se ha ingresado el año, se procede a multiplicarlo por 365 días para un año normal y 366 días para un año bisiesto, según corresponda. Esta operación se condiciona a verificar si se cumple una determinada condición, y en caso afirmativo, se ejecutan las líneas de código que se encuentran dentro de dicha condición.

3.1.3.5 Se realiza una doble verificación al ingresar el año con el fin de determinar si es bisiesto o no. Posteriormente, al ingresar el mes en formato numérico, podemos utilizar una estructura de control de casos para determinar si corresponde a enero, febrero, marzo, etc. Estos valores de mes, a su vez, definen el rango de días correspondientes a cada uno.

3.1.3.6 Para utilizar el sistema de predicción, empleamos un enfoque basado en ecuaciones polinómicas con diversos coeficientes. Esto nos permite generar hasta treinta (30) ecuaciones posibles para la predicción, las cuales luego se promedian para obtener una predicción más confiable. El resultado se presenta en una línea posterior, junto con la fecha (día, mes y año) y el valor de radiación ultravioleta (UV) calculado.

3.1.3.7 En el contexto del uso de la interfaz gráfica con el soporte de la biblioteca Tkinter, se pueden presentar botones para facilitar la interacción del usuario. Al ingresar el día, mes y año, es importante destacar que estos tres valores se tratan como datos numéricos que se calcularán mediante ecuaciones polinómicas de diferentes grados. Esto permite una interacción más intuitiva y sencilla con la aplicación.

Figura 17:

Pantalla GUIDE



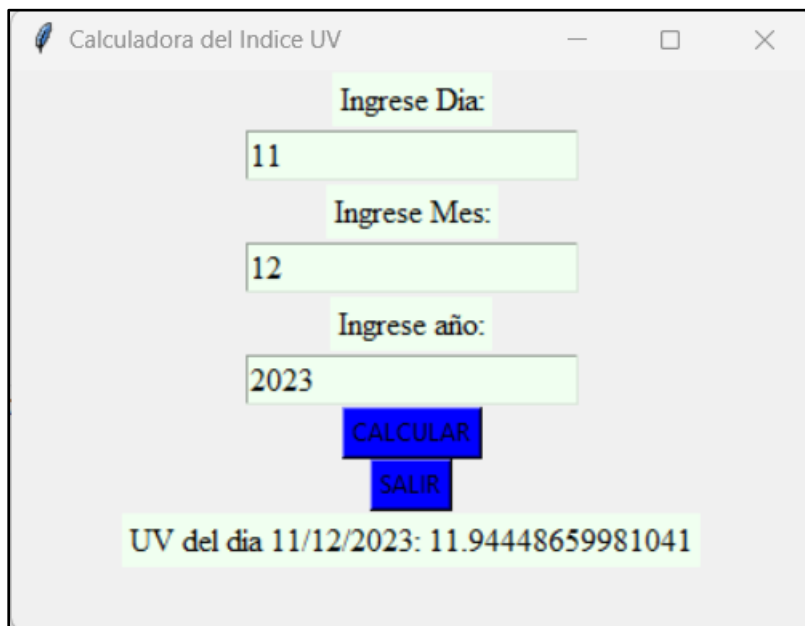
Acá ingresamos los 03 datos que, al ser comparados, funciona de la siguiente manera, primero evalúa el año, si es mayor al 2018, si es bisiesto o no, una vez encontrado eso, analiza el mes, si es de 28, 29, 30 o 31 días y por ultimo compara el día, esto para poder designar un valor a cada día, esto para que cuando ingresemos a nuestra sistema automático pueda predecir el valor futuro

Que necesitamos.

El botón de calcular nos lleva al cálculo empleado para el sistema, mientras el botón de salir nos hace salir de la aplicación.

Figura 20:

Datos ingresados y el valor predictivo



Calculadora del Índice UV

Ingrese Día:
11

Ingrese Mes:
12

Ingrese año:
2023

CALCULAR

SALIR

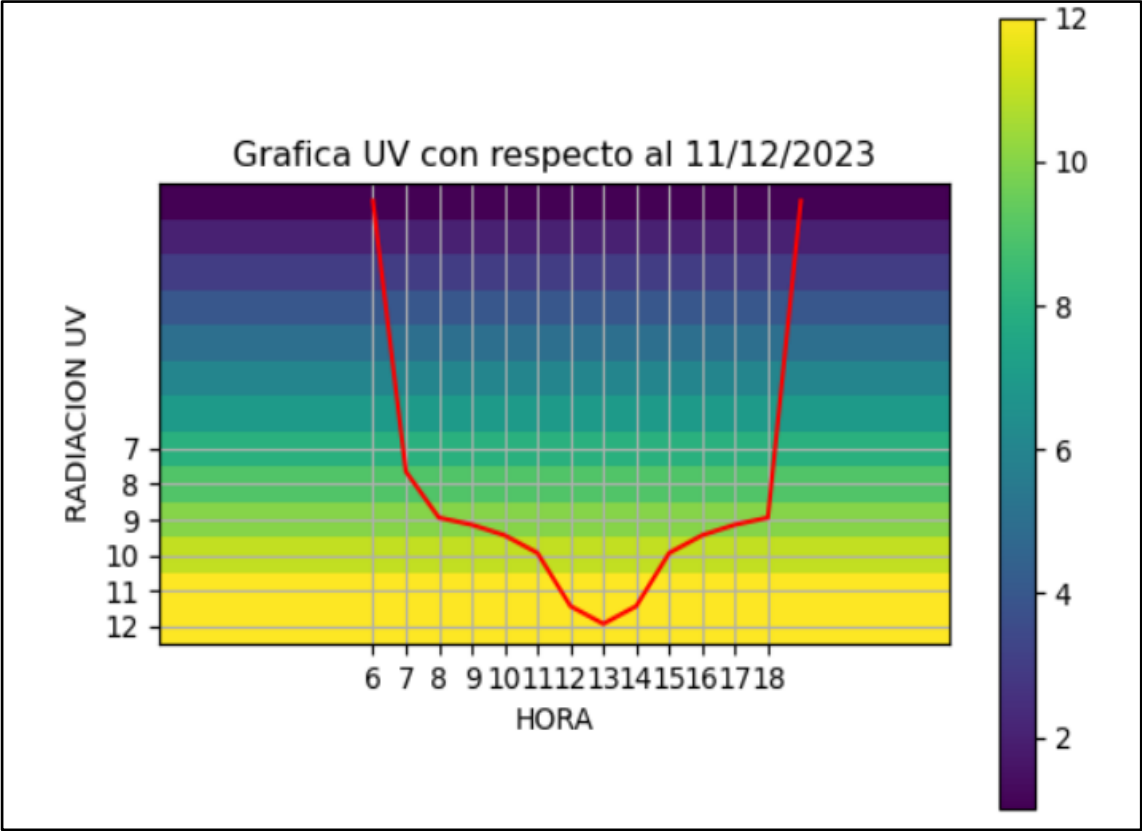
UV del día 11/12/2023: 11.94448659981041

El dato calculado, está dado por la predicción hecha por nuestro sistema, que en consideración del número que se le da a la fecha, se puede calcular el valor aproximado del índice de UV.

3.1.3.8 Resultado del Índice de UV

Para mejor visualización del sistema el software nos entrega la gráfica aproximada del día calculado, esto para poder analizar las variaciones del índice en un día, y como fondo tenemos el índice escalado de la variación de la radiación UV de un rango de 0 a 12 esto para poder saber o a simple vista que tan alto o bajo es el índice de radiación en el día calculado.

Figura 23:
Grafica de la radiación en el día calculado.



3.1.3.9 Cálculos hechos por el sistema de predicción de radiación UV

Figura 26:

Cálculos múltiples de nuestro sistema

Calculadora del Índice UV

Ingrese Día:
4

Ingrese Mes:
8

Ingrese año:
2024

CALCULAR

SALIR

UV del día 4/2/2024: 12.128193834845689

UV del día 4/5/2024: 12.403754687398607

UV del día 4/8/2024: 5.345479452054796

Como observamos en el ejemplo hecho nos muestra el valor calculado en 03 días distintos, así como también nos entrega sus respectivas gráficas, esto para entender la radiación en un día.

Figura 29:

Grafica con respecto al 4 de agosto del 2024

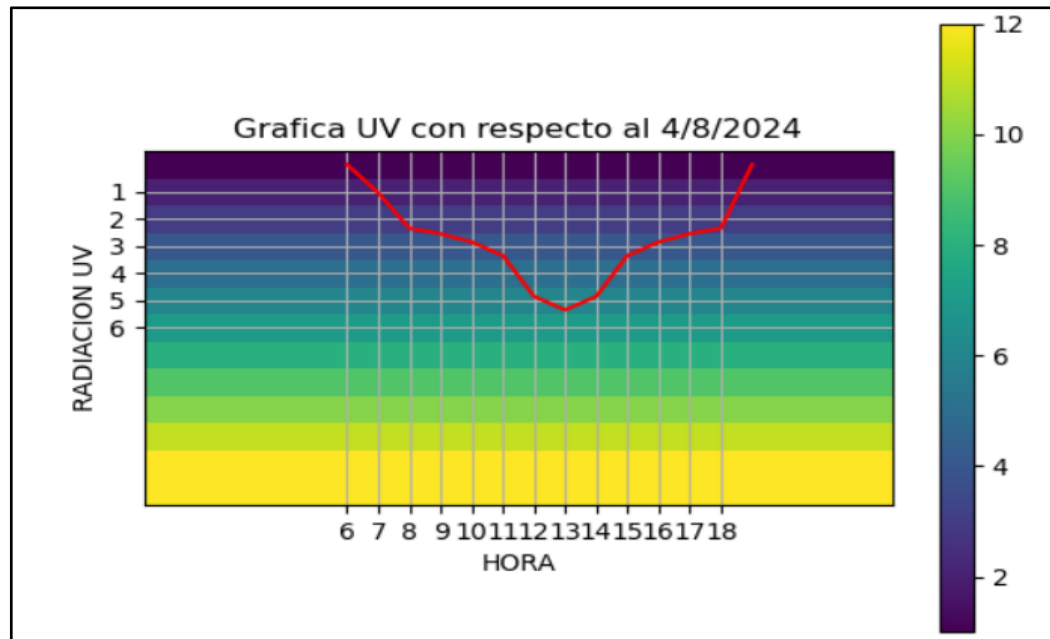


Figura 32:

UV con respecto al 4 de mayo 2024

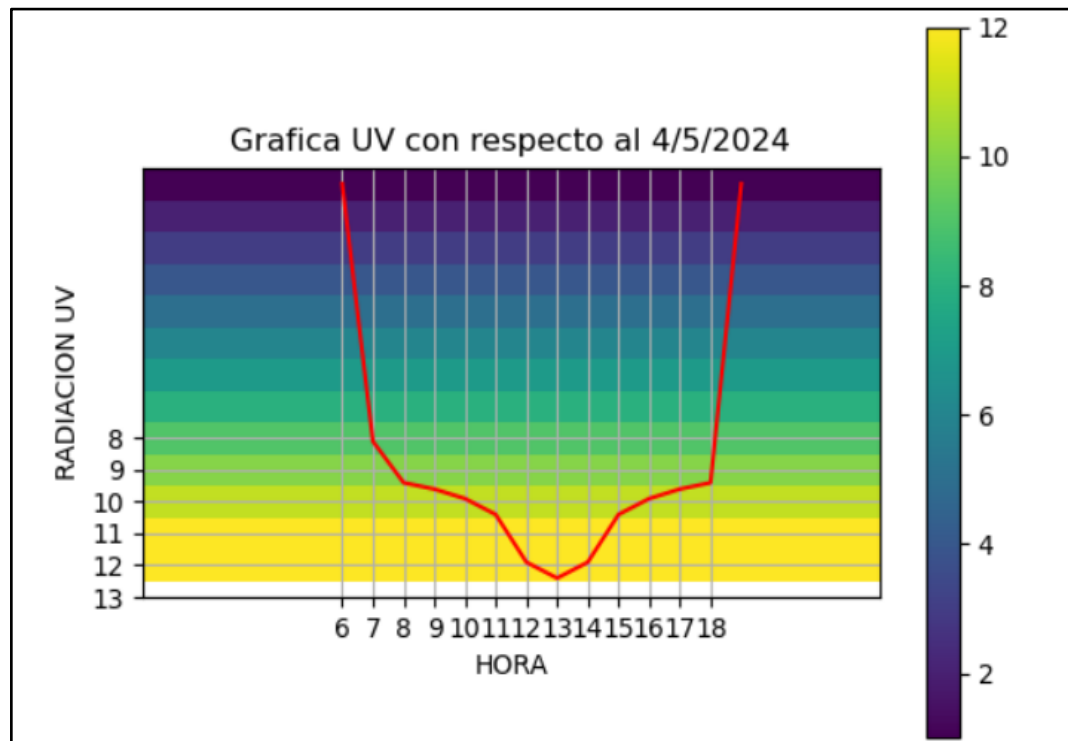
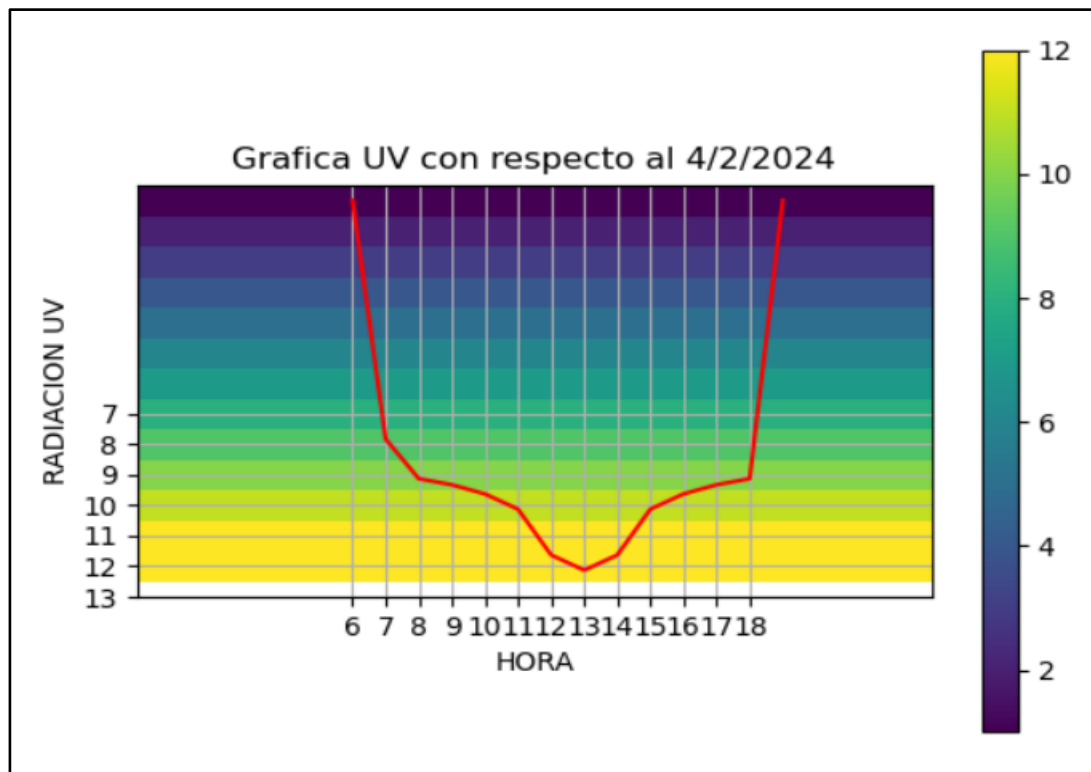


Figura 35:

UV con respecto 4 de febrero del 2024



CAPÍTULO IV

4.1 CONCLUSIONES Y RECOMENDACIONES

4.1.1 CONCLUSIONES

- Tras realizar una exhaustiva revisión literaria, se identificaron y aplicaron diversas técnicas de Machine Learning adecuadas para el desarrollo del modelo predictivo. Esta elección permitió obtener un modelo robusto capaz de capturar las complejidades de los datos y realizar estimaciones precisas del índice de radiación solar ultravioleta.
- El data set de datos de registro de radiación solar ultravioleta en la región Lambayeque es esencial para el entrenamiento y validación del modelo. La disponibilidad de datos confiables contribuyó significativamente a la precisión del modelo final.
- La creación de una base de datos adecuada para el entrenamiento y pruebas del modelo resultó ser un paso crucial en el proceso. La validación de datos y la calibración de parámetros permitieron lograr un desempeño óptimo del modelo, garantizando su capacidad para estimar con precisión en situaciones nuevas.
- El modelo desarrollado tiene una alta capacidad de estimar el índice de radiación solar ultravioleta, puede contribuir a la toma de decisiones informadas en salud pública, actividades al aire libre y medidas de prevención en la exposición solar, así como en el dimensionamiento de sistemas fotovoltaicos.

4.1.2 RECOMENDACIONES

- Se sugiere continuar refinando y mejorando el modelo a medida que se recopilen más datos. La inclusión de nuevas técnicas de Machine Learning y la exploración de enfoques más avanzados podrían llevar a una mayor precisión en las estimaciones.
- Es importante establecer un sistema de monitoreo continuo para actualizar la base de datos con nuevos registros de radiación solar ultravioleta. Esto garantizará que el modelo esté siempre entrenado con los datos más recientes y representativos.
- En futuros trabajos, se recomienda emplear técnicas de validación cruzada para evaluar la robustez y generalización del modelo en diferentes escenarios. Esto ayudará a verificar su desempeño en diversas condiciones y prevenir posibles sesgos.
- Incorporación de Datos Adicionales: Además de los datos de radiación solar ultravioleta, considerar la incorporación de datos meteorológicos adicionales, como temperatura, humedad y velocidad del viento, podría enriquecer el modelo y aumentar su capacidad predictiva.
- Para una implementación efectiva del modelo en medidas de salud pública, se sugiere colaborar con expertos en medicina y salud, de manera que las estimaciones puedan ser interpretadas y utilizadas adecuadamente para la protección de la población.

- Utilizar el modelo de estimación de radiación solar ultravioleta como base para el dimensionamiento de sistemas fotovoltaicos es una extensión valiosa de este trabajo. La capacidad de prever la radiación solar contribuiría a optimizar la eficiencia y el rendimiento de sistemas de energía solar.

REFERENCIAS

- Abril, L., Azogue, F., Chancusig, K., Suárez, R., & León, M. (2019). *Obtención y comparación del índice de la radiación solar en el barrio "San Felipe" de la ciudad de Latacunga en el año 2019 / Abril Chafla / Ciencias de la Ingeniería y Aplicadas*.
<http://investigacion.utc.edu.ec/revistasutc/index.php/ciya/article/view/252/188>
- Agresti, A. (2018). *Statistical methods for the social sciences* (Fifth edition). Pearson.
https://api.pageplace.de/preview/DT0400.9781292220345_A37747447/preview-9781292220345_A37747447.pdf
- Bénard, C., Biau, G., Veiga, S. da, & Scornet, E. (2021). Interpretable Random Forests via Rule Extraction. *Proceedings of The 24th International Conference on Artificial Intelligence and Statistics*, 937-945. <https://proceedings.mlr.press/v130/benard21a.html>
- Burgos-Blasco, P., Melian-Olivera, A., & Vañó-Galván, G. S.-E. Y. S. (2022). Indicaciones y tratamiento fotoprotector. *Medicine - Programa de Formación Médica Continuada Acreditado*, 13(47), 2775-2778. <https://doi.org/10.1016/j.med.2022.01.008>
- Cruz, J. (2020). *Diseño e implementación de un sistema de monitoreo de la radiación ultravioleta en la ciudad de Arequipa*. [Universidad Nacional de San Agustín de Arequipa]. <https://repositorio.unsa.edu.pe/server/api/core/bitstreams/db21daae-e0a6-45da-84e7-6d0bd681f66c/content>
- Friedberg, R., Tibshirani, J., Athey, S., & Wager, S. (2021). Local Linear Forests. *Journal of Computational and Graphical Statistics*, 30(2), 503-517.
<https://doi.org/10.1080/10618600.2020.1831930>

- Gan, Z. S., Wood, C. M., Hayon, S., Deal, A., Smith, A. B., Tan, H.-J., & Pruthi, R. S. (2020). Correlation of Relative Value Units With Surgical Complexity and Physician Workload in Urology. *Urology*, 139, 71-77. <https://doi.org/10.1016/j.urology.2019.12.044>
- Gastelo, J., Morales, A., & Tineo, J. (2018). *Estimación de la radiación solar diaria y ángulos de inclinación óptimos para Lambayeque (Perú) utilizando el modelo de Hargreaves-Samani*. https://www.researchgate.net/profile/Jose-Gastelo-Roque/publication/327541883_Estimacion_de_la_radiacion_solar_diaria_y_angulos_de_inclinacion_optimos_para_Lambayeque_Peru_utilizando_el_modelo_de_Hargreaves-Samani/links/5b94af6892851c78c4017e57/Estimacion-de-la-radiacion-solar-diaria-y-angulos-de-inclinacion-optimos-para-Lambayeque-Peru-utilizando-el-modelo-de-Hargreaves-Samani.pdf
- Gentili, J., & Campo, A. (2020). *La radiación solar en Bahía Blanca* [Tesis Doctoral]. <https://redalyc.org/revista.oa?id=3832>
- González, M., Tamayo, M., & Sánchez, Á. (2009). *La Radiación Ultravioleta. Su Efecto Dañino Y Consecuencias Para La Salud Humana*. 18.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144. <https://doi.org/10.1145/3422622>
- Hao, P.-Y., Chiang, J.-H., & Chen, Y.-D. (2022). Possibilistic classification by support vector networks. *Neural Networks*, 149, 40-56. <https://doi.org/10.1016/j.neunet.2022.02.007>
- Kozmin, S., Slezak, G., Reynaud-Angelin, A., Elie, C., de Rycke, Y., Boiteux, S., & Sage, E. (2005). UVA radiation is highly mutagenic in cells that are unable to repair 7,8-dihydro-8-oxoguanine in *Saccharomyces cerevisiae*. *Proceedings of the National Academy of*

- Sciences of the United States of America*, 102(38), 13538-13543.
<https://doi.org/10.1073/pnas.0504497102>
- Kullavanijaya, P., & Lim, H. W. (2005). Photoprotection. *Journal of the American Academy of Dermatology*, 52(6), 937-958. <https://doi.org/10.1016/j.jaad.2004.07.063>
- Kutlubay, Z., Sevim, A., Engin, B., & Tüzün, Y. (2014). Photodermatoses, including phototoxic and photoallergic reactions (internal and external). *Clinics in Dermatology*, 32(1), 73-79. <https://doi.org/10.1016/j.clindermatol.2013.05.027>
- Lyons, A. B., Trullas, C., Kohli, I., Hamzavi, I. H., & Lim, H. W. (2021). Photoprotection beyond ultraviolet radiation: A review of tinted sunscreens. *Journal of the American Academy of Dermatology*, 84(5), 1393-1397. <https://doi.org/10.1016/j.jaad.2020.04.079>
- Rigel, D. S., Lim, H. W., Draelos, Z. D., Weber, T. M., & Taylor, S. C. (2022). Photoprotection for all: Current gaps and opportunities. *Journal of the American Academy of Dermatology*, 86(3), S18-S26. <https://doi.org/10.1016/j.jaad.2021.12.023>
- Rodríguez, M. (2020). *Estudio sobre los efectos de la radiación en el espectro electromagnético sobre la salud humana* [Tesis de grado, UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA].
<http://repositorio.unitec.edu/bitstream/handle/123456789/11964/21541091-octubre2020-i04-pg.pdf.pdf?sequence=1&isAllowed=y>
- Sharma, P. N., Shmueli, G., Sarstedt, M., Danks, N., & Ray, S. (2021). Prediction-Oriented Model Selection in Partial Least Squares Path Modeling. *Decision Sciences*, 52(3), 567-607. <https://doi.org/10.1111/dec.12329>

Valavi, R., Elith, J., Lahoz, J., & Guillerá, G. (2021). Modelling species presence-only data with random forests. *Ecography* 44: 1731–1742, 2021.

<https://mirror.rcg.sfu.ca/mirror/CRAN/web/packages/RRF/RRF.pdf>

Yaulilahua, R., Palomino, P., Huere, J., Yaulilahua, M., Castañeda, C., & Gonzales, T. (2022).

Cuantificación del índice UV en la ciudad de Huancavelica, periodo: 2018-2019. *Ciencia Latina Revista Científica Multidisciplinar*, 6(3), Article 3.

https://doi.org/10.37811/cl_rcm.v6i3.2237

ANEXOS

DESARROLLO DEL MODELO REDICTIVO

```
import pandas as pd
import numpy as np
import tkinter as tk
ventana = tk.Tk()
ventana.geometry('400x280')
ventana.title('Calculadora del Indice UV')
m1=0
suma=0
j=0
d=0
prediccionUV=0
def calcular():
    suma=0
    j=0
    d=0
    data=pd.read_csv("Data2018-2019.csv", delimiter=";")
    x=data['Fecha']
    x2=data['Dia']
    y=data['Radiacion']
    def fx (x1, coef):
        fx = 0
        n = len(coef) - 1
        for p in coef:
            fx = fx + p*x1**n
            n = n - 1
        return fx
    ANHO=str((b3.get()))
    if (ANHO %4==0 and ANHO>2018):
        print("Año bisiesto")
    MES=str((b2.get()))
    match MES:
        case 1:
            print("Enero")
            m1=0
            DIA=str((b1.get()))
            if DIA>=1 and DIA<=31:
                print(str(DIA)+" de Enero del "+str(ANHO))
```

Para el uso del software se necesitan las librerías, tkinter, Numpy, pandas, este último sirve para poder indexar la data desde un archivo .csv, para posteriormente procesar, dado que los datos que vamos a predecir es una variable independiente, usamos el análisis predictivo a base de una ecuación polinómica, el cual permite, analizar los posibles resultados (predicción UV)

```
    else:
        print("error")
case 2:
    print("Febrero")
    m1=31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=29:
        print(str(DIA)+" de Febrero del "+str(ANHO))
    else:
        print("error")
case 3:
    print("Marzo")
    m1=31+29
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Marzo del "+str(ANHO))
    else:
        print("error")
case 4:
    print("Abril")
    m1=31+29+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Abril del "+str(ANHO))
    else:
        print("error")
case 5:
    print("Mayo")
    m1=31+29+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Mayo del "+str(ANHO))
    else:
        print("error")
```

En la variable de día, mes y año, son datos que van a estar limitados, y para poder controlar de manera correcta, se debe comparar, la cantidad de día que tiene un mes, y si ese día se encuentra en el rango establecido, así como, si el año es un bisiesto, saber que el día 29 de febrero va a existir y debe tener un dato para ese día.

```
case 6:
    print("Junio")
    m1=31+29+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Junio del "+str(ANHO))
    else:
        print("error")
case 7:
    print("Julio")
    m1=31+29+31+30+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Julio del "+str(ANHO))
    else:
        print("error")
case 8:
    print("Agosto")
    m1=31+29+31+30+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Agosto del "+str(ANHO))
    else:
        print("error")
case 9:
    print("Setiembre")
    m1=31+29+31+30+31+30+31+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Setiembre del "+str(ANHO))
    else:
        print("error")
```

Como resultado tenemos un limitador de rango que va desde el día 1 hasta el día 28, 29, 30 o 31 dependiendo al mes que corresponda y el año, para esto, se ha visto la viabilidad de crear una función que permita determinar el año ingresado, si es bisiesto o no, de ser automáticamente el día 29 se ingresa como día que se puede predecir, esto para garantizar que solo se puede trabajar con fechas reales.

Cuando el año ingresado no es bisiesto, automáticamente el año tendrá 365 datos que se puedan predecir, esto se dividen en mes, y día, con esto datos predecimos el dato que queremos, dado que el día, mes y año, usando que al año ingresado lo restamos “2018” que es el año de inicio de la base de datos, esto se toma para la ecuación, una vez ingresado el año, se pretende a multiplicar x 365 días año normal, y 366 días año bisiesto, esto se hace con la condición de si se cumple una condición entonces ejecuto las líneas de programa que están dentro de esa condición.

```

case 10:
    print("Octubre")
    m1=31+29+31+30+31+30+31+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Octubre del "+str(ANHO))
    else:
        print("error")
case 11:
    print("Noviembre")
    m1=31+29+31+30+31+30+31+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Noviembre del "+str(ANHO))
    else:
        print("error")
case 12:
    print("Diciembre")
    m1=31+29+31+30+31+30+31+31+30+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Diciembre del "+str(ANHO))
    else:
        print("error")
if (ANHO !=0 and ANHO%4 !=0 and ANHO>2018):
    MES=str((b2.get()))
    match MES:
        case 1:
            print("Enero")
            m1=0
            DIA=str((b1.get()))
            if DIA>=1 and DIA<=31:
                print(str(DIA)+" de Enero del "+str(ANHO))
            else:
                print("error")

```

```

case 2:
    print("Febrero")
    m1=31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=28:
        print(str(DIA)+" de Febrero del "+str(ANHO))
    else:
        print("error")
case 3:
    print("Marzo")
    m1=31+28
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Marzo del "+str(ANHO))
    else:
        print("error")
case 4:
    print("Abril")
    m1=31+29+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Abril del "+str(ANHO))
    else:
        print("error")
case 5:
    print("Mayo")
    m1=31+29+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Mayo del "+str(ANHO))
    else:
        print("error")

```

Se hace una comparacion doble en el ingreso del año, para poder saber si es o no bisiesto, luego una vez ingresado el mes, numerico, podemos determinar por funcion de casos, que si el mes es enero, febrero, marzo, etc. Y estos mismo delimitan el rango de los dias.

```

case 6:
    print("Junio")
    m1=31+29+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Junio del "+str(ANHO))
    else:
        print("error")
case 7:
    print("Julio")
    m1=31+29+31+30+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Julio del "+str(ANHO))
    else:
        print("error")
case 8:
    print("Agosto")
    m1=31+29+31+30+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Agosto del "+str(ANHO))
    else:
        print("error")
case 9:
    print("Setiembre")
    m1=31+29+31+30+31+30+31+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Setiembre del "+str(ANHO))
    else:
        print("error")

```

```

case 10:
    print("Octubre")
    m1=31+29+31+30+31+30+31+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Octubre del "+str(ANHO))
    else:
        print("error")
case 11:
    print("Noviembre")
    m1=31+29+31+30+31+30+31+31+30+31
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=30:
        print(str(DIA)+" de Noviembre del "+str(ANHO))
    else:
        print("error")
case 12:
    print("Diciembre")
    m1=31+29+31+30+31+30+31+31+30+31+30
    DIA=str((b1.get()))
    if DIA>=1 and DIA<=31:
        print(str(DIA)+" de Diciembre del "+str(ANHO))
    else:
        print("error")
if(ANHO<2018):
    f2=tk.Label(ventana,text="Error",bg='honeydew',fg='black',font='Times 12')
    f2.pack(padx=1,pady=1,ipadx=1,ipady=1)
if (ANHO%4==0):
    v3=(ANHO-2018)*366
if (ANHO%4!=0):
    v3=(ANHO-2018)*365

v2=m1
v1=DIA
fecha=v1+v2+v3
print(fecha)

```

```

for i in range(0,30):
    coef = np.polyfit(x2,y,i)
    p = np.polyval(coef, fecha)
    if p>=1 and p<=20:
        suma=suma+p
        j+=1
    prediccionUV=suma/j
    d1=2*prediccionUV-5
    ##print("La Prediccion de UV Alta en el dia es: ",prediccionUV)
    ##print("La Prediccion UV Promedio en el dia seria de:",(d1)/2)
    f1=tk.Label(ventana,text="UV del dia "+str(DIA)+"/"+str(MES)+"/"+str(ANHO)+": "+
        str(prediccionUV),bg='honeydew',fg='black',font='Times 12')
    f1.pack(padx=1,pady=1,ipadx=1,ipady=1)
    d1=(prediccionUV/prediccionUV)-1
    d6=prediccionUV-4.3
    d7=prediccionUV-3
    d8=prediccionUV-2.8
    d9=prediccionUV-2.5
    d10=prediccionUV-2
    d11=prediccionUV-0.5
    d12=prediccionUV

```

Para el uso de la prediccion se se utiliza el sistema de prediccion basado en ecuacion polinomica con distintos coeficientes, esto para poder determinar en 30 posibles ecuaciones la prediccion se promedia, para poder determinar una prediccion mas aceptable, este resultado se mostrara en una linea posterior con el dia, mes, año y el valor de UV calculado.

Para el uso de la interfaz grafica con apoyo de la librería Tkinter, podemos mostrar los botones, para poder interactuar de una manera mas simple, dado que al ingresar el dia, mes y año, estos 3 datos van a ser un dato numerico, que va ser calculado mediante ecuacion polinomial de diferentes grados.

Figura 38:

Efectos de la Radiación Infrarroja en la Piel en las personas.

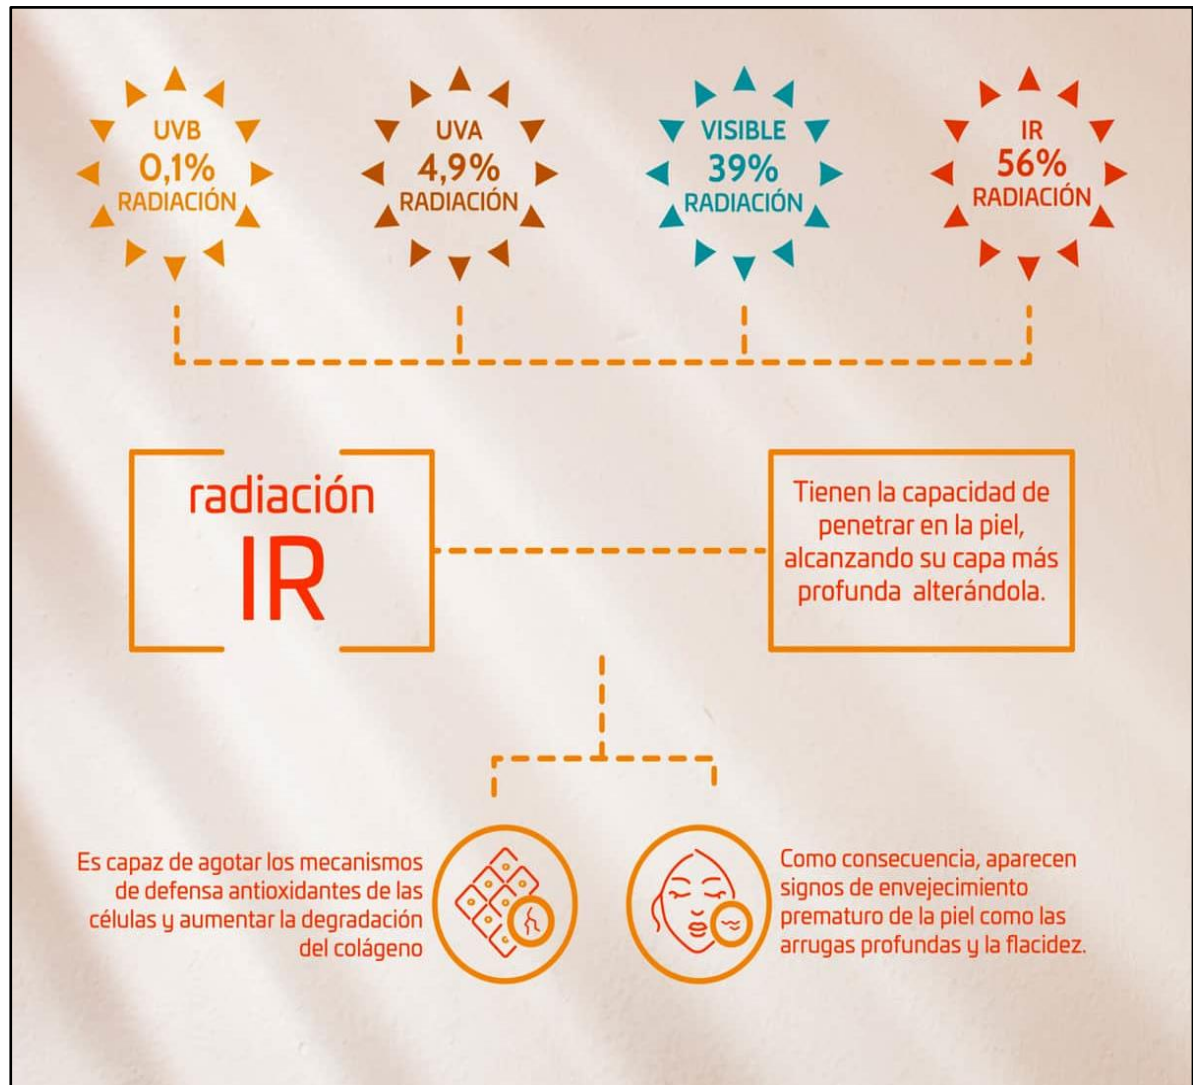


Figura 41:

La radiación UV puede perjudicar a los ojos y el tejido que los rodea.

