

Estimation of the Ultraviolet Index Using Artificial Intelligence Techniques

Ciro William Taipe Huaman¹; Eva Genoveva Mendoza Mamani²; Matias Huillca Arbieto³; Hugo Hernan Flores Laine⁴,

¹Universidad Nacional de Juliaca, Perú, c.taipe@unaj.edu.pe

^{2,3}Universidad Nacional del Altiplano, Perú, emendoza@unap.edu.pe, mhuillca@unap.edu.pe

⁴Universidad Nacional Intercultural de Quillabamba, Perú, hugo.flores@uniq.edu.pe

Abstract– Ultraviolet radiation poses a significant risk to human health, as it is associated with sunburn, premature aging, skin cancer, and ocular damage. Peru records UV index levels ranging from 14 to 20, which are considered among the highest worldwide, thereby highlighting the need for reliable monitoring and prediction systems. In this study, a predictive model was developed to estimate the maximum UV index using meteorological variables, including temperature, humidity, heat index, barometric pressure, solar radiation, and solar energy, through the application of machine learning techniques to historical records collected from the DAVIS Vantage PRO 2.0 meteorological station located in Puno during the 2017–2024 period. Following data cleaning, exploratory analysis, and model training, linear regression and Random Forest approaches were evaluated, with solar radiation and solar energy identified as the most influential predictors. Although linear regression achieved a satisfactory fit ($R^2 = 0.87$), the Random Forest algorithm demonstrated superior performance ($R^2 = 0.95$, $MAE \approx 0.75$), with homogeneously distributed residuals and no evidence of systematic bias. Consequently, decision tree–based methods emerge as robust tools for real-time UV index estimation, with potential applications in public health, risk prevention, and the planning of outdoor activities.

Keywords– Ultraviolet index, predictive model, artificial intelligence, solar radiation, public health.

Estimación del índice ultravioleta mediante técnicas de inteligencia artificial

Ciro William Taipe Huaman¹; Eva Genoveva Mendoza Mamani²; Matias Huilca Arbieto³; Hugo Hernan Flores Laime⁴

¹Universidad Nacional de Juliaca, Perú, c.taipe@unaj.edu.pe

^{2,3}Universidad Nacional del Altiplano, Perú, emendoza@unap.edu.pe, mhuilca@unap.edu.pe

⁴Universidad Nacional Intercultural de Quillabamba, Perú, hugo.flores@uniq.edu.pe

Resumen— La radiación ultravioleta constituye un riesgo significativo para la salud humana, al estar asociada con quemaduras solares, envejecimiento prematuro, cáncer cutáneo y daños oculares. El Perú presenta niveles de índice UV entre 14 y 20, considerados entre los más altos del mundo, lo que refuerza la necesidad de sistemas de monitoreo y predicción confiables. En el presente estudio se desarrolló un modelo predictivo para estimar el valor máximo del índice UV a partir de variables meteorológicas, incluyendo temperatura, humedad, índice de calor, presión barométrica, radiación solar y energía solar, mediante la aplicación de técnicas de aprendizaje automático sobre registros históricos de la estación meteorológica DAVIS Vantage PRO 2.0 ubicada en Puno, correspondientes al periodo 2017–2024. Tras las etapas de depuración de datos, análisis exploratorio y entrenamiento, se compararon modelos de regresión lineal y Random Forest, identificándose la radiación y la energía solar como los predictores de mayor influencia. Si bien la regresión lineal mostró un ajuste satisfactorio ($R^2 = 0.87$), el algoritmo Random Forest presentó un desempeño superior ($R^2 = 0.95$, $MAE \approx 0.75$), con residuos homogéneos y sin evidencia de sesgo sistemático. En consecuencia, los enfoques basados en árboles de decisión se consolidan como herramientas robustas para la estimación del índice UV en tiempo real, con potencial aplicación en salud pública, prevención de riesgos y planificación de actividades al aire libre.

Palabras clave— Índice ultravioleta, modelo predictivo, inteligencia artificial, radiación solar, salud pública.

I. INTRODUCCIÓN

En la actualidad, la información de los valores del índice ultravioleta se obtiene de las bases de datos proporcionadas en la web, como la que ofrece el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), que son valores promedio diarios para grandes regiones, que difieren de los valores estimados en tiempo real, debido a las características del lugar y el tipo de clima que se presenta [1]. Debido a ello los valores promedio diarios del índice ultravioleta (UVI) difieren de los valores estimados en tiempo real, considerando que la intensidad de la radiación solar varía durante el día y con un periodo anual [2].

En el Perú, mediante la Ley N° 30102 promulgada en 2013, se establecen disposiciones orientadas a la prevención de los efectos adversos en la salud derivados de la exposición prolongada a la radiación solar. Esta normativa tiene como

finalidad definir medidas preventivas de cumplimiento obligatorio para instituciones y entidades, tanto públicas como privadas. El artículo 7, referido a la difusión de los niveles de radiación solar, asigna esta responsabilidad al Servicio Nacional de Meteorología e Hidrología del Perú. No obstante, los valores publicados en su sitio web corresponden a estimaciones para amplias áreas geográficas y se presentan como promedios diarios, por lo que no representan mediciones en tiempo real. Además, dichos valores pueden diferir de los registros in situ debido a la influencia de condiciones atmosféricas locales, como la nubosidad y la presencia de aerosoles. Según SENAMHI, en el Perú se percibe niveles de radiación UV entre 14-20 [3], siendo de las más altas del mundo, causando distintas enfermedades a la piel. Asimismo, existen más de 7 millones de trabajadores expuestos al sol día a día [4].

Los sistemas actuales de monitoreo del UVI en Perú, como los reportados por SENAMHI, ofrecen valores promedio diarios en grandes áreas geográficas, lo que limita su utilidad en la prevención inmediata de riesgos locales, pues no capturan la variabilidad espacial ni temporal asociada a factores como nubosidad o aerosoles. Aplicaciones móviles y sensores de dispositivos electrónicos han intentado suplir esta necesidad, pero presentan limitaciones por depender de promedios globales o de factores indirectos de radiación, sin garantizar mediciones confiables en tiempo real.

Otra alternativa para la obtención del índice UV consiste en el uso de instrumentos de medición especializados, como espectrorradiómetros y dispositivos portátiles, los cuales proporcionan resultados de alta precisión. Sin embargo, su principal limitación radica en que estos equipos no se encuentran fácilmente disponibles para la población en general. Aunque existen sistemas y redes de medición del índice UV, su cobertura geográfica es limitada y, en muchas regiones, los datos no se registran en tiempo real, dificultando la prevención y la toma de decisiones oportunas.

La exposición excesiva a la radiación ultravioleta (UV) representa un riesgo significativo para la salud humana, provocando afecciones como quemaduras solares, envejecimiento prematuro, reacciones de tipo alérgicas, como foto-queratitis [5], cáncer en la piel [6]. En los ojos causa cataratas [7] y afecta al sistema inmunológico [8]. El efecto

más común de la sobreexposición a la radiación solar es la quemadura solar o eritema, que aparece 10-16 horas después de la exposición al sol [9]. La radiación ultravioleta es fundamental para la salud en pequeñas cantidades, ya que permite que el cuerpo fabrique vitamina D para reforzar el sistema óseo y osteomuscular [10]. Los efectos en la naturaleza como en la agricultura y la vida acuática se presentan en las plantas y peces [11]. En la vegetación afectando a su crecimiento [12], [13], en la conservación y durabilidad de materiales como el plástico y la pintura [14].

La llegada de sistemas predictivos expertos inspirados en IA puede abordar con solidez las desventajas de los métodos mecanicistas y deterministas, en particular en la predicción del UVI solar. Las plataformas de predicción ML y DL basadas en IA son conocidas por exhibir una inmensa eficiencia computacional y estos algoritmos son muy hábiles en el manejo de la no linealidad en los conjuntos de datos de entrada [15]. El potencial de la técnica ML ha sido explorado en la predicción del UVI a largo plazo a escala global utilizando una red neuronal artificial (RNA) multicapa de propagación hacia adelante [16]. Los avances en inteligencia artificial (IA) ofrecen una alternativa robusta. Modelos híbridos y explicables como el EJH-X-DNN [15] y el W-O-convLSTM [17] han mostrado alta precisión en predicciones del UVI, alcanzando correlaciones superiores a 0.96. Asimismo, la IA permite integrar datos satelitales, meteorológicos y geográficos con técnicas de optimización que mejoran la exactitud y ofrecen interpretabilidad [18], [19], [20].

El empleo de técnicas de inteligencia artificial (IA) en la estimación de la radiación solar y ultravioleta ha mostrado avances significativos en los últimos años. Diversos estudios se han enfocado en modelos híbridos que combinan arquitecturas profundas y métodos de aprendizaje automático para mejorar la precisión frente a la variabilidad atmosférica. En Australia, Ghimire, Deo, et al. (2022) desarrollaron el modelo híbrido CXGBRFR, que integra CNN, Gradient Boosting, Random Forest y optimización Harris Hawks, alcanzando un desempeño superior frente a modelos convencionales en la predicción de radiación solar global. De manera similar, Ghimire, Bhandari, et al. (2022) propusieron el modelo CSVR, basado en CNN y SVR, optimizado con selección de características, mostrando resultados más precisos que ocho métodos de referencia.

En el ámbito europeo, Guijo-Rubio et al. (2020) lograron predicciones altamente precisas de radiación solar en España utilizando redes neuronales evolutivas entrenadas exclusivamente con datos satelitales, lo que resalta la viabilidad de estos enfoques para estimar el UVI en ausencia de estaciones terrestres [21]. En la misma línea, Peng et al. (2021) desarrollaron un modelo híbrido que combina descomposición CEEMDAN, BiLSTM y optimización mediante algoritmo seno-coseno (SCA), superando a siete técnicas de referencia en predicciones multihorizonte [22].

Las revisiones recientes refuerzan la pertinencia de los modelos híbridos. Guermoui et al. (2020) concluyen que los enfoques individuales son insuficientes para capturar la variabilidad atmosférica, destacando que la integración de múltiples técnicas de IA mejora la precisión y la aplicabilidad en contextos solares [23]. Más recientemente, Naveed et al. (2024) introdujeron el modelo TIR, que combina BiLSTM, GRU y mecanismos de atención, alcanzando un desempeño superior ($R^2 = 0.9983$), evidenciando el potencial de arquitecturas avanzadas en el modelado de variables atmosféricas [20].

Asimismo, Ghimire et al. (2023) propusieron el modelo CMLP, que combina CNN y MLP optimizados mediante RF-RFE, obteniendo resultados superiores en múltiples escalas temporales respecto a catorce enfoques alternativos [24]. De manera específica para el UVI, Prasad et al. (2022) desarrollaron un modelo trifásico W-O-convLSTM, validado en Queensland, que alcanzó correlaciones de hasta 0,961 en horizontes de 10 a 60 minutos, demostrando un gran potencial para generar alertas en tiempo real y contribuir a la prevención de riesgos en salud pública [17].

En conjunto, estos avances evidencian que el uso de modelos y arquitecturas profundas basadas en IA constituye una estrategia prometedora para la estimación del índice ultravioleta, al integrar de manera eficaz datos atmosféricos, satelitales y meteorológicos para aplicaciones en salud, energía y gestión ambiental.

Por lo tanto, la presente investigación se justifica en la necesidad de desarrollar un modelo predictivo basado en IA que permita estimar valores de UVI y de forma localizada en regiones de alta radiación como Puno. Este avance contribuirá a la prevención de enfermedades cutáneas y oculares, fortalecerá las estrategias de salud pública y proporcionará información confiable para la formulación de políticas de mitigación de riesgos ambientales y ocupacionales.

II. METODOLOGÍA

Se desarrolló una investigación de enfoque cuantitativo, de tipo aplicado, con diseño no experimental y alcance predictivo. Se realizó un estudio observacional retrospectivo con series temporales registradas por los sensores de la estación meteorológica DAVIS Vantage PRO 2.0. El objetivo fue modelar el Índice UV máximo en función de variables meteorológicas temperatura, humedad, índice de calor, presión barométrica, radiación solar y energía solar mediante técnicas de machine learning, considerando un total de 182756 registros de datos correspondientes al periodo 2017-2024.

A. Lugar de estudio

La investigación se desarrolló en la Universidad Nacional del Altiplano-Puno (UNAP), ubicada en la ciudad de Puno, al sur del Perú. Esta institución se localiza en las coordenadas geográficas 15.83° de latitud sur y 70.083° de longitud oeste, a una altitud aproximada de 3 820 m s. n. m.

B. Datos atmosféricos en la ciudad de Puno

Se utilizaron datos correspondientes al período 2017–2024, recopilados mediante la estación meteorológica DAVIS Vantage PRO 2.0 Plus. En intervalos de 15min considerando datos de en el intervalo de 6:00am 18:00pm. El equipo dispone de certificación de calibración emitida por el fabricante. Como se muestra en la Figura 1, la estación meteorológica está instalada en un espacio abierto, libre de sombras y obstrucciones, en el pabellón de Ingeniería Civil de la UNAP, ubicada en las coordenadas geográficas -15.4890 de latitud y -70.1515 de longitud, a una altitud de 3 825 m s. n. m. Considerando los datos medidos: temperatura, humedad, índice de calor, presión barométrica, radiación solar, energía solar e índice UV.



Fig. 1 Estación meteorológica DAVIS vantage PRO 2.0 Plus.

C. Procesamiento de datos

En la construcción del modelo propuesto para pronosticar el UVI en el horizonte horario, la primera etapa consiste en la extracción de datos. De la estación meteorológica para la ciudad de Puno. En el periodo 01 de enero del 2017 al 31 de diciembre del 2024, considerando datos medidos de diurno.

La segunda etapa del modelado UVI. Fue importante examinar cuidadosamente los conjuntos de datos extraídos para localizar cualquier dato faltante. Los datos se limpiaron eliminando registros nocturnos. La imputación de ausentes se realizó por interpolación temporal.

En la tercera etapa, se llevó a cabo un Análisis Exploratorio de Datos (EDA) empleando diferentes técnicas estadísticas y gráficas. En primer lugar, se generaron histogramas para analizar la distribución de las variables y detectar posibles sesgos o asimetrías. Posteriormente, se construyó una matriz de correlación con el fin de identificar relaciones lineales entre las variables. Además, se aplicaron los gráficos de Autocorrelación (ACF) y Autocorrelación Parcial (PACF), útiles para evaluar la dependencia temporal de las series.

La cuarta etapa Se dividieron los datos manteniendo la secuencia temporal: 80% para entrenamiento y 20% para prueba. Para la validación e hiperparametrización se empleó TimeSeriesSplit (k=4).

En la quinta etapa, se diseña el modelo. Para desarrollar la secuencia de modelos, se implementó un lenguaje de programación Python de renombre a través de la plataforma Google Colab con una interfaz Jupyter Notebook de libre acceso, compatible con una unidad de procesamiento tensorial (TPU) y una unidad de procesamiento gráfico (GPU). El entorno virtual de la potente herramienta Python proporciona paquetes excepcionales para la ejecución de algoritmos de aprendizaje automático (ML) y aprendizaje automático (DL).

El procesamiento y modelado de datos se realizó utilizando bibliotecas especializadas de Python como Scikit-learn, Pandas y NumPy.

D. Índice ultravioleta

El UVI se representa matemáticamente como:

$$UVI = \frac{1}{25mWm^{-2}} \int_{290}^{400} S(\lambda) \cdot E_{UV}(\lambda) \cdot d\lambda \quad (1)$$

Donde E_{UV} es la energía espectral $Wm^{-2}nm^{-1}$ medida en las longitudes de onda terrestres de 290 a 400 nm, y $S(\lambda)$ es la efectividad relativa del eritema en cada longitud de onda discreta.

E. Estadísticos de evaluación

Con el fin de cuantificar la precisión y la capacidad predictiva de los modelos desarrollados, se emplearon métricas estadísticas ampliamente utilizadas en estudios de validación de modelos meteorológicos y ambientales. En particular, se consideraron la raíz del error cuadrático medio (RMSE), el error medio o sesgo (MBE), el error medio absoluto (MAE), el coeficiente de determinación (R^2) y el coeficiente de correlación lineal (r). Estos indicadores permiten evaluar tanto la magnitud de los errores como el grado de asociación entre los valores medidos y estimados.

Las métricas se determinaron a partir de las siguientes expresiones:

$$RMSE_{\%} = \frac{100}{\bar{I}_{mi}} \left[\frac{\sum_{i=1}^n (I_{mi} - I_{ci})^2}{n} \right]^{1/2} \% \quad (2)$$

$$MBE_{\%} = \frac{100}{\bar{I}_{mi}} \frac{\sum_{i=1}^n (I_{mi} - I_{ci})}{n} \% \quad (3)$$

$$MAE_{\%} = \frac{100}{\bar{I}_{mi}} \frac{\sum_{i=1}^n |I_{mi} - I_{ci}|}{n} \% \quad (4)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (I_{mi} - \bar{I}_{mi})(I_{ci} - \bar{I}_{ci}) \right]^2}{\left[\sum_{i=1}^n (I_{mi} - \bar{I}_{mi})^2 \right] \left[\sum_{i=1}^n (I_{ci} - \bar{I}_{ci})^2 \right]} \quad (5)$$

$$r = \sqrt{R^2} \quad (6)$$

donde I_{mi} corresponde al valor observado por la estación meteorológica, I_{ci} al valor estimado por el modelo, $\bar{I}_{mi}$ y $\bar{I}_{ci}$ representan los promedios de las observaciones y predicciones, respectivamente, y n indica el número total de registros analizados.

Para la interpretación del desempeño, se adoptó la clasificación reportada en la literatura especializada para RMSE y MABE, considerando: excelente ($RMSE < 10\%$), bueno ($10\% \leq RMSE < 20\%$), aceptable o regular ($20\% \leq RMSE < 30\%$) y deficiente ($RMSE \geq 30\%$). Criterios equivalentes se aplicaron al MABE.

III. RESULTADOS

A. Distribución de las variables

En la figura 2, se presentan la distribución de las variables: Temperatura, Humedad e Índice de calor presentan distribuciones aproximadamente normales, lo cual es coherente con fenómenos atmosféricos regulares. Presión barométrica muestra un rango estrecho de variación, indicando que en la zona de estudio no existen grandes fluctuaciones de altitud o clima extremo. Radiación solar y Energía solar evidencian distribuciones sesgadas hacia valores bajos, reflejando que la mayor parte del tiempo la radiación no alcanza niveles máximos (probablemente por nubosidad o variaciones diurnas). Índice UV presenta alta concentración en valores bajos (cercanos a cero), lo cual corresponde a registros nocturnos o de baja radiación. Esto confirma la necesidad de filtrar valores de $UV=0$ para mejorar la calidad del modelo predictivo. Los datos tienen distribuciones razonables y consistentes con la física del fenómeno solar.

Distribución de las variables




Fig. 2 Distribución de las variables.

B. Matriz de correlación

En la figura 3, existe alta correlación (0.98) entre Temperatura e Índice de calor, lo cual indica redundancia. Se puede considerar eliminar una de ellas en futuros modelos para evitar colinealidad. Radiación solar y Energía solar también muestran una correlación muy fuerte (0.88), reforzando la idea de que ambas describen el mismo fenómeno físico. El Índice UV presenta correlación más fuerte con Radiación solar (0.42) y Energía solar (0.40), lo cual es consistente con la base científica: el UV depende directamente de la radiación incidente. Humedad y presión barométrica no tienen correlaciones fuertes con el Índice UV, lo que sugiere que su aporte al modelo será limitado. Las variables clave para la predicción del Índice UV son la radiación y la energía solar.




Fig. 3 Matriz de correlación.

C. Resultados de Regresión Lineal

La figura 4, muestra una Métricas: $MAE \approx 1.35$, $RMSE \approx 1.57$, $R^2 \approx 0.87$. El modelo lineal explica un 87% de la variabilidad del Índice UV, lo que es notable, aunque deja un error promedio de más de una unidad UV. El gráfico Real vs Predicho muestra que la recta de regresión se ajusta bien en rangos intermedios, pero existen desviaciones en valores extremos (subestimación en valores altos y sobrestimación en bajos). La regresión lineal captura la relación general, pero no logra modelar la no linealidad de los datos.




Fig. 4 Regresión lineal: Real vs predicho.

D. Resultados de Random Forest

En la figura 5, Métricas: $MAE \approx 0.75$, $RMSE \approx 0.99$, $R^2 \approx 0.95$. Mejora sustancial respecto a la regresión lineal: el error promedio disminuye casi a la mitad y la varianza explicada alcanza un 95%.




Fig. 5 Índice UV: real vs predicho.

En la figura 6, temporal Real vs Predicho, la curva predicha sigue muy de cerca la real, aunque en picos máximos aún se observan pequeñas desviaciones. El gráfico de dispersión Real vs Predicho muestra puntos concentrados alrededor de la diagonal, lo que confirma un buen ajuste. Random Forest es un modelo más adecuado para capturar la complejidad no lineal de la relación entre radiación y UV.




Fig. 6 RandomForest: Real vs predicho.

E. Importancia de variables

En la figura 7, se muestra la importancia de la variables. La variable más influyente es Radiación solar (~45%), seguida por Energía solar (~40%). La Humedad, Presión barométrica, Temperatura e Índice de calor tienen importancia marginal, lo que confirma que el Índice UV depende fundamentalmente de la radiación incidente y no de otras condiciones atmosféricas. El modelo confirma la teoría física: el UV es esencialmente una función de la radiación solar.




Fig. 7 Importancia de variables (RandomForest).

F. Distribución de residuales

En la figura 8, Los residuales de Random Forest se distribuyen aproximadamente en forma de campana centrada en cero, lo que indica ausencia de sesgo sistemático. Sin embargo, se observan colas alargadas, lo que sugiere que el modelo aún tiene dificultad para capturar valores atípicos de

UV (probablemente en días despejados con máxima radiación).




Fig. 8 Distribución de residuales.

El Figura 9, de residuales en el tiempo muestra variabilidad alrededor de cero, sin tendencia clara, lo que sugiere estabilidad del modelo. El modelo es robusto, pero puede mejorarse aplicando técnicas de detección de outliers o ajustando hiperparámetros para capturar mejores valores extremos.




Fig. 9 Residuales en el tiempo.

Radiación solar y Energía solar son las variables dominantes en la predicción del Índice UV. La regresión lineal es aceptable como modelo base, pero presenta limitaciones en los extremos. El Random Forest mejora sustancialmente el ajuste, con un R^2 de 0.95.

El análisis de residuales confirma un modelo estable, aunque con oportunidades de mejora para capturar valores atípicos. Se recomienda filtrar valores de UV=0 (nocturnos), optimizar hiperparámetros del Random Forest o probar modelos más avanzados como XGBoost o LightGBM para mejorar el rendimiento en valores máximos.

IV. CONCLUSIONES

El estudio confirma que es posible predecir el índice UV máximo a partir de variables meteorológicas mediante técnicas de inteligencia artificial, con alta precisión y coherencia respecto a la teoría física. La radiación solar y la energía solar son las variables dominantes en el modelo, lo que valida su rol

central en la determinación del índice UV. Factores como temperatura, humedad y presión barométrica mostraron una influencia marginal. La regresión lineal permitió explicar el 87% de la variabilidad del UV, aunque con limitaciones para valores extremos. En contraste, Random Forest alcanzó un R^2 del 95% y redujo significativamente los errores de predicción, evidenciando su mayor capacidad para capturar relaciones no lineales. El análisis de residuales evidenció estabilidad y ausencia de sesgo sistemático en el modelo Random Forest, aunque persisten desafíos en la predicción de valores atípicos. Se recomienda explorar algoritmos más avanzados, como XGBoost o LightGBM, y optimizar los hiperparámetros para mejorar el desempeño en escenarios de radiación extrema.

REFERENCIAS

- [1] M. Huilca, C. W. Taipe, and M. Saavedra, "Índice Ultravioleta en la ciudad de Puno para cielos claros," *Revista de Investigaciones Altoandinas - Journal of High Andean Research*, vol. 19, no. 2, pp. 211–218, Jun. 2017, doi: 10.18271/ria.2017.280.
- [2] M. Moraes, "Interaction between vitamin D supplementation and sunlight exposure in women living in opposite latitudes (the D-SOL study)," University of Surrey, 2019.
- [3] SENAMHI - Perú, "Pronóstico de radiación UV máximo (cielo despejado y mediodía solar) a nivel nacional." Accessed: Jun. 05, 2023. [Online]. Available: <https://www.senamhi.gob.pe/?p=radiacion-uv>
- [4] PALMERA, "Ley 30102: Todo acerca de Su correcto cumplimiento (2022)." Accessed: Jun. 05, 2023. [Online]. Available: <https://palmera.pe/ley-30102/>
- [5] T. M. Ansary, M. R. Hossain, K. Kamiya, M. Komine, and M. Ohtsuki, "Inflammatory molecules associated with ultraviolet radiation-mediated skin aging," *International Journal of Molecular Sciences*, vol. 22, no. 8, 2021, doi: 10.3390/ijms22083974.
- [6] R. P. Gallagher and T. K. Lee, "Adverse effects of ultraviolet radiation : A brief review," *Progress in Biophysics and Molecular Biology* 92, vol. 92, pp. 119–131, 2006, doi: 10.1016/j.pbiomolbio.2006.02.011.
- [7] C. McCarty and H. R. Taylor, "Light and Risk for Age-Related Eye Diseases," *NUTRITIONAL and ENVIRONMENTAL INFLUENCES on the EYE*, pp. 135–150, May 2021, doi: 10.1201/9781003208785-8.
- [8] J. J. Bernard, R. L. Gallo, and J. Krutmann, "Photoimmunology: how ultraviolet radiation affects the immune system," *Nature Reviews Immunology*, vol. 19, no. 11, pp. 688–701, 2019, doi: 10.1038/s41577-019-0185-9.
- [9] S. T. Wolf, L. E. Kenney, and W. L. Kenney, "Ultraviolet Radiation Exposure, Risk, and Protection in Military and Outdoor Athletes," *Current sports medicine reports*, vol. 19, no. 4, pp. 137–141, 2020, doi: 10.1249/JSR.0000000000000702.
- [10] R. E. Neale et al., *The effects of exposure to solar radiation on human health*. Springer International Publishing, 2023. doi: 10.1007/s43630-023-00375-8.
- [11] M. Sweet, N. Kirkham, M. Bendall, L. Currey, J. Bythell, and M. Heupel, "Evidence of melanoma in wild marine fish populations," *PLoS ONE*, vol. 7, no. 8, Aug. 2012, doi: 10.1371/journal.pone.0041989.
- [12] B. A. Kunz, D. M. Cahill, P. G. Mohr, M. J. Osmond, and E. J. Vonarx, "Plant Responses to UV Radiation and Links to Pathogen Resistance," *International Review of Cytology*, vol. 255, no. 06, pp. 1–40, 2006, doi: 10.1016/S0074-7696(06)55001-6.
- [13] L. Zhang, L. Hartwell, A. Jr, M. M. Vaughan, B. A. Hauser, and K. J. Boote, "Agricultural and Forest Meteorology Solar ultraviolet radiation exclusion increases soybean internode lengths and plant height," *Agricultural and Forest Meteorology*, vol. 184, no. July 2011, pp. 170–178, 2014, doi: 10.1016/j.agrformet.2013.09.011.
- [14] A. L. Andradý et al., "Effects of UV radiation on natural and synthetic materials," *Photochemical and Photobiological Sciences*, no. 0123456789, 2023, doi: 10.1007/s43630-023-00377-6.
- [15] S. S. Prasad, R. C. Deo, S. Salcedo-Sanz, N. J. Downs, D. Casillas-Pérez, and A. V. Parisi, "Enhanced joint hybrid deep neural network explainable

- artificial intelligence model for 1-hr ahead solar ultraviolet index prediction,” *Comput Methods Programs Biomed*, vol. 241, Nov. 2023, doi: 10.1016/j.cmpb.2023.107737.
- [16] J. N. Latosińska, M. Latosińska, and J. Bielak, “Towards modelling ultraviolet index in global scale. Artificial neural networks approach,” *Aerosp Sci Technol*, vol. 41, pp. 189–198, 2015, doi: 10.1016/j.ast.2014.12.013.
- [17] S. S. Prasad, R. C. Deo, N. Downs, D. Igoe, A. V. Parisi, and J. Soar, “Cloud Affected Solar UV Prediction with Three-Phase Wavelet Hybrid Convolutional Long Short-Term Memory Network Multi-Step Forecast System,” *IEEE Access*, vol. 10, pp. 24704–24720, 2022, doi: 10.1109/ACCESS.2022.3153475.
- [18] S. Ghimire, R. C. Deo, D. Casillas-Pérez, and S. Salcedo-Sanz, “Boosting solar radiation predictions with global climate models, observational predictors and hybrid deep-machine learning algorithms,” *Appl Energy*, vol. 316, Jun. 2022, doi: 10.1016/j.apenergy.2022.119063.
- [19] S. Ghimire, B. Bhandari, D. Casillas-Pérez, R. C. Deo, and S. Salcedo-Sanz, “Hybrid deep CNN-SVR algorithm for solar radiation prediction problems in Queensland, Australia,” *Eng Appl Artif Intell*, vol. 112, Jun. 2022, doi: 10.1016/j.engappai.2022.104860.
- [20] M. S. Naveed *et al.*, “Leveraging advanced AI algorithms with transformer-infused recurrent neural networks to optimize solar irradiance forecasting,” *Front Energy Res*, vol. 12, 2024, doi: 10.3389/fenrg.2024.1485690.
- [21] D. Guijo-Rubio *et al.*, “Evolutionary artificial neural networks for accurate solar radiation prediction,” *Energy*, vol. 210, Nov. 2020, doi: 10.1016/j.energy.2020.118374.
- [22] T. Peng, C. Zhang, J. Zhou, and M. S. Nazir, “An integrated framework of Bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting,” *Energy*, vol. 221, Apr. 2021, doi: 10.1016/j.energy.2021.119887.
- [23] M. Guermoui, F. Melgani, K. Gairaa, and M. L. Mekhalfi, “A comprehensive review of hybrid models for solar radiation forecasting,” Jun. 10, 2020, *Elsevier Ltd*. doi: 10.1016/j.jclepro.2020.120357.
- [24] S. Ghimire *et al.*, “Hybrid Convolutional Neural Network-Multilayer Perceptron Model for Solar Radiation Prediction,” *Cognit Comput*, vol. 15, no. 2, pp. 645–671, Mar. 2023, doi: 10.1007/s12559-022-10070-y.